

VISOKO UČILIŠTE ALGEBRA

DIPLOMSKI RAD

**KORIŠTENJE VIZUALIZACIJSKIH TEHNIKA
KOD SNA ANALIZE U UVJETIMA
INFORMACIJSKOG RATOVANJA**

Srečko Zajec

Zagreb, veljača 2018.

Predgovor

Ovaj rad je posvećen Diani Zajec (1957-2016).

Proces izrade rada odvijao se kroz dvije faze: osmišljavanje ideje i razrada koncepata odvijalo se tijekom rujna i listopada 2017., dok je glavna analiza nad podacima i završno pisanje provedeno kroz studeni i prosinac iste godine. Rad je revidiran i formalno završen tijekom siječnja i veljače 2018. godine. U tom pogledu prva faza izrade mogla bi se okarakterizirati daleko izazovnijom u smislu razrade temeljnih ideja, a druga faza repetitivnijom u pogledu korištenja podataka.

Autor smatra da tematika informacijskog ratovanja nikada nije bila aktualnija i to upravo iz razloga jer sva vezana zbivanja imaju značajan utjecaj na svakodnevni život građana globalno pa tako i u Republici Hrvatskoj. Pokušaj razmatranja navedene problematike kroz tehnološku prizmu, odnosno procese analiziranja i naprednog vizualiziranja podataka tako (možda) doprinese jačanju opće svijesti o ovoj izrazito bitnoj temi koja najčešće sakrivena od očiju šire javnosti. Također, razrada ove teme istovremeno je poslužila kao inicijalni nacrt u pogledu osmišljavanja okvira koji će poslužiti drugim istraživačima i budućim radovima. Navedeno vrijedi i za različite moguće nadogradnje u pogledu dodatnih istraživanja te posljedičnog objavljivanja proširenih radova slične tematike.

Potpisnik ovih redaka ovim bi se putem zahvalio profesorima Visokog učilišta Algebra koji su na autora uspješno prenijeli dio svojeg znanja te direktno omogućili izradu rada. To se poglavito odnosi na predmet posvećen vizualizaciji podataka (doc. dr. sc. Leo Mršić - ujedno i mentor te g. Zdravko Kunić), kolegij koji obrađuje SNA analizu (doc. dr. sc. Robert Kopal i g. Saša Krnjašić) te finalno, skupinu predmeta koji obrađuju strukturirane i kreativne analitičke tehnike (gđa. Darija Korkut). Zahvalu za tehničkoj pomoći također valja uputiti i korisnicima Facebook grupe¹ posvećenu softverskom alatu „Gephi“ te članu tima koji razvija alat „NodeXL“ (g. Marc Smith).

¹ Facebook. *Gephi Group*. <https://www.facebook.com/groups/gephi/> (06.02.2018.)

Sažetak

Hrvatski:

Rad se bavi problematikom informacijskog ratovanja u kontekstu propagiranja vijesti na društvenim mrežama koja predstavlja izrazito dinamično i kompleksno područje. Aktualnost teme, a ujedno i izrazito mali broj radova iz ovog područja, zahtijevala je sveobuhvatan i sistematičan pristup u razradi ovog rada. Iz razloga praktičnosti pribjeglo se tematici rada koji se bazira na vizualizaciji mrežnih podataka o specifičnim aktivnostima na socijalnim mrežama (Facebook) korištenjem SNA analize. Postupak se sastoji od razvoja temeljnog modela, povlačenja podataka, njihove obrade te posljedične analize i vizualizacije, a što je detaljno obrađeno u radu zajedno s komentarima vezanima uz način primjene.

Ključne riječi: napredna vizualizacija, socijalne mreže, informacijsko ratovanje, SNA (Social Network Analysis)

English:

This paper deals with the information warfare in the context of news propagation through social networks which is an extremely dynamic and complex area to study. Due to topic actuality and a very small number of works on the similar topic this paper required a comprehensive and systematic approach. Thus, for practical reasons this work is based on the usage of social network analysis (SNA) and visualization of social networking data obtained through Facebook. The process consists of the development of the underlying model, the retrieval of data, data processing and consequential analysis & visualization which has been elaborated in detail along with the comments related to the methods of application.

Keywords: advanced visualization, social networks, information warfare, SNA (Social Network Analysis)

Sadržaj

Predgovor	3
Sažetak.....	4
Sadržaj	5
1. Uvod	1
2. Temeljne pretpostavke	2
2.1. Hibridni rat i informacijsko ratovanje.....	2
2.2. Društvene mreže.....	3
2.3. Osnovna terminologija metoda analize socijalnih mreža	5
2.4. Vizualizacija podataka.....	8
3. Područje analize.....	10
3.1. Eksplorativna analiza i njezine značajke.....	10
3.2. Informacijsko ratovanje kao alat za ostvarivanje interesnih ciljeva.....	12
3.3. Komunikacija putem socijalnih mreža	17
4. Strukturiranje podataka prema pretpostavljenom modelu mreže	20
4.1. Razvoj osnovnog modela mreže	20
4.2. Kontekstualizacija osnovnog modela	25
4.3. Popis grupiranih stranica.....	30
4.3.1. Grupa stranica N/Nesvrstana	30
4.3.2. Grupa stranica D/Politički desno orijentirana	31
4.3.3. Grupa stranica L/Politički lijevo orijentirana.....	36
5. Povlačenje i priprema podataka	45
5.1. Povlačenje podataka	45
5.2. Priprema podataka	48
6. Analiza i vizualizacija podataka	52
6.1. Opis najvažnijih funkcionalnosti softvera te pregled osnovnog procesa analize i vizualizacije.....	52
6.2. Vizualizacija mreže Facebook stranica grupe D	55
6.3. Vizualizacija mreže Facebook stranica grupe L i grupe N	69
6.4. Utjecaj interesnih grupacija i primjeri iz prakse	83
7. Preporuke	89

Zaključak.....	93
Popis slika	95
Popis tablica	97
Literatura.....	99

1. Uvod

Zbivanja u ekonomskim, političkim i tehnološkim sferama u današnje su vrijeme kompleksnija no ikad prije. U takvom svijetlu razumijevanje zamršenih odnosa zahtjeva sustavni analitički pristup koji omogućuje potpunije shvaćanje svih događanja koja se odvijaju oko nas. Kao jedno od temeljnih pitanja koje će se provlačiti kroz naredna poglavlja jest da li je moguće uz ograničene resurse, jeftina i/ili besplatna softverska rješenja te javno dostupne podatke donositi kvalitetne zaključke temeljem provođenja procesa analize i vizualizacije podataka. Navedeno će se bazirati na proučavanju odnosa između aktera na društvenim mrežama i utvrđivanju njihova potencijala u pogledu informacijskog ratovanja. U tom smislu informacijsko ratovanje će se analizirati kroz prizmu propagiranja informacija, prvenstveno vijesti, koje za svrhu imaju promoviranje određenih interesnih ciljeva.

Gore istaknuta temeljna pitanja možemo promatrati i kao svojevrsnu uvodnu hipotezu. Preciznije rečeno, postavlja se pitanje da li je moguće postaviti okvire za temeljne postupke koji bi se uz manje preinake lako mogli implementirati u velikim sustavima i pretpostavljeni model analize podigli na jednu višu operativnu ili stratešku razinu. Kako je većina radnji u nastavku provedena u laboratorijskim uvjetima dio rada sadrži i preporuke koji bi doprinijeli upravo daljnjoj razradi.

Iako je glavni fokus stavljen na analizu i vizualizaciju podataka veći dio ovog rada pokriva razvoj osnovnog koncepta, povlačenje te načine korištenja podataka. Takva razdioba nije nimalo neuobičajena i podudara se s uobičajenim praksama koje se najčešće javljaju kod sličnih procesa - većina vremena otpada na sveukupnu pripremu, a tek manji dio na analizu podataka.

Brzina protoka informacija u 21. stoljeću je zastrašujuće velika. U vremenima stalnih političkih previranja, ekonomskih nestabilnosti i sukobljavanja različitih interesnih sfera društvene okolnosti se mijenjaju gotovo svakodnevno, ne samo globalno, već sve više i na lokalnim razinama. Bez obzira na to, informacijsku vrijednost za donošenje odluka stvaraju upravo analize i vizualizacije, a kako je to postignuto u domeni koja se dotiče ratovanja informacijama bit će prezentirano u nastavku.

2. Temeljne pretpostavke

2.1. Hibridni rat i informacijsko ratovanje

U periodu nastanka ovog rada (jesen/zima 2017-2018.) u hrvatskim medijima pojavio se i ubrzo postao izrazito popularan pojam „hibridno ratovanje“. Postoje nedoumice vezane uz točnu definiciju tog pojma. Jedna definicija podrazumijeva korištenje propagande, dezinformacija, hakerskih napada i informacijskog ratovanja da bi se ostvario neki politički, ekonomski i drugi cilj. Druga opisuje osmišljen, nadziran i centraliziran skup aktivnosti, otvoren ili prikriven, s kombinacijom vojnog i nevojnog djelovanja dok treća govori da je to kombinacija specijalnog rata i korištenja interneta.²

NATO Review magazin tako daje najopćenitiju, ali ujedno i najjasniju definiciju hibridnog rata: hibridni rat je onaj koji nije ograničen na jednu dimenziju ratovanja, odnosno podrazumijeva korištenje različitih drugih metoda osim čiste vojne sile.³

Izraz je u zadnje vrijeme posebno populariziran nakon izbijanja krize na Krimu i ruskoj aneksiji tog poluotoka⁴ pri čemu treba jasno razdvojiti pojam „hibridni rat“ s jedne strane te „informacijsko ratovanje“ s druge te naglasiti da navedeni pojmovi nisu kakav novi konstrukt već postoje dulje vrijeme. U tom kontekstu informacijsko ratovanje je tek jedan od mogućih elemenata hibridnog rata.

Definicija informacijskog ratovanja prema Ministarstvu obrane SAD-a ide u prilog tome da se radi o procesu koji omogućava upravljanje tokom informacija kako bi se postigli određeni ciljevi nad određenim protivnikom te istodobno njega onemogućilo da čini isto nama.⁵ Budući da je pojam informacijskog ratovanja relativno uži i sadrži manje elemenata, isti će kao takav biti u fokusu rada i to kroz analizu i vizualizaciju podataka, a sve kako bi lakše uočili uzročno-posljedične veze pripadajućih procesa.

² Večernji list. *Što je to hibridni rat i vodi li se on u Hrvatskoj?*

<https://www.vecernji.hr/vijesti/sto-je-to-hibridni-rat-i-vodi-li-se-on-u-hrvatskoj-1210522> (30.11.2017.)

³ NATO Review. *Hybrid war - does it even exist?*

<https://www.nato.int/docu/review/2015/Also-in-2015/hybrid-modern-future-warfare-russia-ukraine/EN> (01.12.2017.)

⁴ RENZ, B., SMITH, H. *Russia And Hybrid Warfare - Going Beyond The Label*. Helsinki: Kikimora Publications, 2016., str. 22-23.

⁵ Global Information Assurance Certification. *Information Warfare*.

<https://www.giac.org/paper/gsec/1870/information-warfare/103284> (30.11.2017.)

2.2. Društvene mreže

Ključ u razumijevanju informacijskog ratovanja leži u činjenici da se alati kojima se postižu ciljevi istog danas uglavnom baziraju na tehnološkim rješenjima dok prije to nije bio nužno slučaj. U tom pogledu komunikacijske i informacijske tehnologije bivaju savršen instrument za tako nešto budući da pružaju mogućnost prijenosa i prezentiranja informacija na način na koji to pošiljalac odredi.

Nadalje, jedan od glavnih čimbenika u stjecanju informacijske prednosti ispred protivnika leži u našoj mogućnosti ekstrakcije velikih količina podataka, definiranju ključnih točki u informacijskom prostoru i primjerenom djelovanju temeljem analiza i donesenih zaključaka.⁶ U tom pogledu globalne IT tvrtke igraju ključnu ulogu budući da na raspolaganju imaju velike količine podataka koji slijedom toga postaju iznimno vrijedne. Posljedično, društvene mreže, odnosno tvrtke koje njima upravljaju bivaju savršeni primjer za promatranje zbog činjenice da omogućavaju prijenos informacija, a analizom javnih ili privatnih podataka u tom kontekstu omogućuje se donošenje zaključaka o potencijalnim entitetima od interesa.

Ranije je navedeno da pojam informacijskog ratovanja nije nov već se razvojem tehnologije zapravo promijenio način djelovanja. To također podrazumijeva da je razvoj tehnologije u potpunosti promijenio okolinu u kojoj sudjeluju kreatori, prenositelji i primatelji informacija. Veliki medijski konglomerati više nisu usamljeni u tom prostoru već su i puno manje organizacije, tvrtke te pojedinci dobili moć upravljanja tijekom informacija i to prvenstveno zahvaljujući društvenim mrežama.⁷

Velika količina podataka koja se generira radom društvenih mreža može biti zanimljiva za različite vrste analiza no ono po čemu su takve mreže najzanimljivije svakako jest činjenica da kreiraju podatke o socijalnim interakcijama što nam u pogledu ranije opisanog informacijskog prostora svakako može biti od koristi da shvatimo što se u našoj interesnoj sferi zapravo događa. U tom pogledu podaci o socijalnim interakcijama su zapravo relacijski podaci, odnosno podaci koji nam

⁶ R. GERY, W., LEE, S., NINAS, J. *Information Warfare in an Information Age*. Washington, DC: NDU Press, Joint Force Quarterly, Vol. 85, 2017., 22-29, str. 23.

⁷ The Intercept. *The New Information Warfare*.

<https://theintercept.com/2017/11/25/information-warfare-social-media-book-review-gaza> (01.12.2017.)

govore tko komunicira s kim, tko su prijatelji, tko ima slične interese, a temeljem takvih podataka moguće je stvoriti informacije koje pomažu u lakšem razumijevanju komunikacijskih procesa.⁸ Nastavno, u takvom okruženju bitno je znati razlučiti tko stvara, a tko konzumira informacije⁹, a sve kako bi mogli pratiti tijek istih i proučavati uzročno-posljedične veze, odnosno potencijal širenja informacija. Ako problematici pristupimo na takav način više nismo samo puki promatrači, već se stavljamo u poziciju da možemo upravljati takvim procesima i preokrenuti ih u vlastitu korist. Sličan primjer iz života možemo pronaći kod arhitekture, odnosno urbanog planiranja gdje se kroz dizajn zgrada, ulica i općenito gradske infrastrukture uvelike može utjecati na način na koji ljudi komuniciraju jedni s drugima.¹⁰

Prijenos informacija i informacijsko ratovanje kao takvi se ne događaju isključivo i jedino na društvenim mrežama. Ipak, dinamičnost i brzina promjena na ovakvim platformama čini ih idealnim za potencijalni predmet proučavanja. Uzevši u obzir resursna ograničenja u kojima nastaje ovaj rad, prvenstveno budžetna, trebamo se zapitati koji je najlakši način za dolaženje do potencijalnih podataka koji će nam omogućiti analizu procesa koji bi mogli dovoljno zorno prikazati utjecaj informacijskog ratovanja. Pri tome valja napomenuti da nepostojanje budžeta predstavlja značajan faktor utjecaja, posebice ako navedeno stavimo u odnos s količinom podataka koje veliki moderni sustavi generiraju na dnevnoj bazi. Tako je samo Facebook u 2014. godini dnevno obrađivao oko 600TB podataka.¹¹

Bez obzira što većina podataka na društvenim mrežama biva u vlasništvu njihovih vlasnika (tvrtki), jedan određeni dio je javno dostupan te se različitim alatima može analizirati i shodno tome pomoći u izvlačenju zaključaka od našeg interesa. Ovaj rad će se bazirati upravo na takvoj vrsti javno dostupnih podataka te njihovom posljedičnom obradom korištenjem metrika analize socijalnih mreža (skraćeno SNA, eng. *Social Network Analysis*.)

⁸ HANSEN, D., SHNEIDERMAN, B., SMITH, M. *Analyzing Social Media Networks with NodeXL*. Burlington, MA: Morgan Kaufmann, Kindle Edition, 2011., str. 12.

⁹ HANSEN, D., SHNEIDERMAN, B., SMITH, M. *Analyzing Social Media Networks with NodeXL*. Burlington, MA: Morgan Kaufmann, Kindle Edition, 2011. str. 13.

¹⁰ HANSEN, D., SHNEIDERMAN, B., SMITH, M. *Analyzing Social Media Networks with NodeXL*. Burlington, MA: Morgan Kaufmann, Kindle Edition, 2011., str. 11.

¹¹ Facebook Code. *Scaling the Facebook data warehouse to 300 PB*.

<https://code.facebook.com/posts/229861827208629/scaling-the-facebook-data-warehouse-to-300-pb/> (06.02.2018.)

2.3. Osnovna terminologija metoda analize socijalnih mreža

U ovom djelu bit će opisani osnovni pojmovi koji se vežu uz SNA analizu kako bi u kasnijim dijelovima ovog rada iste učinkovito mogli koristiti u interpretaciji podataka dobivenima uz pomoć analitičkih softverskih programa. Istodobno je bitno naglasiti da će ovo poglavlje poslužiti isključivo za pregled najosnovnijih pojmova koji se koriste u pogledu takvih analiza jer SNA tehnike obuhvaćaju izuzetno veliko područje, a čijom bi se detaljnom razradom udaljili od glavne teme ovog rada.

Kroz prethodno poglavlje definiran je prijenos informacija u onom najosnovnijem obliku: od ishodišta do cilja. Te dvije točke možemo nazvati akterima, entitetima ili čvorovima (eng. *node*), a njihovu međusobnu poveznicu vezom.¹² Kako se u realnom svijetu susrećemo s velikim brojem *node-ova* i njihovih veza (koji čine mrežu) njihove međusobne odnose nije moguće lako razumjeti pa u tom smislu trebamo koristiti analitičke metode koje će nam u tome pomoći. Takozvana analiza mreža nudi rješenje za ovu vrstu problematike, a ovaj rad se naslanja na najvišu razinu takve analize zvanu *Social Network Analysis* (skraćeno SNA). Radi se o strukturnoj analizi različitih vrsta veza koje nalazimo svuda oko nas, gdje god postoji neki oblik socijalne interakcije. Ova se vrsta analize najčešće provodi pomoću programskih alata (eng. *software*) kako bi se izračunale različite varijable, odnosno metrike koje govore o tome kako unutar mreže jedan *node* utječe na drugi.¹³ Bez obzira što se SNA često koristi za analizu međuljudskih odnosa valja napomenuti da ista omogućuje analiziranje različitih mrežnih struktura bilo da se one javljaju u prirodi ili su umjetno stvorene. U ovom konkretnom radu Facebook profile i stranice valja definirati kao entitete, a o čemu će biti riječi u narednim poglavljima.

Postoje različite razine SNA analize i u tom smislu valja razlikovati razinu individualnih aktera (*node-ova*) gdje proučavamo utjecaj pojedinog entiteta, dijadnu razinu (dva entiteta), trijadnu razinu (tri entiteta), razinu podgrupe (pojedine komponente mreže, odnosno skupinu većeg broja entiteta) i globalnu razinu (mrežu

¹² KOPAL, R., KORKUT, D., KRNJASIĆ, S. *Analiza (socijalnih) mreža: praktična primjena*. Zagreb: IN2data d.o.o. / Visoko učilište Algebra, 2016., str. 56.

¹³ KOPAL, R., KORKUT, D., KRNJASIĆ, S. *Analiza (socijalnih) mreža: praktična primjena*. Zagreb: IN2data d.o.o. / Visoko učilište Algebra, 2016., str. 84.

u cjelini).¹⁴ U narednim poglavljima razrada problematike će se provoditi najčešće na razini individualnih *node-ova*, ali i izračunima koji se odnose na dijelove ili kompletnu mrežu.

Matematički izračuni, odnosno mjere centraliteta koje nam govore o važnosti pojedinih *node-ova* su sljedeći:¹⁵

Mjera centraliteta	Opis
Degree	Broj dolaznih i odlaznih veza nekog čvora
Closeness	Udaljenost jednog čvoara do drugog. Mjera je veća što u manjem broju koraka možemo doseći neki drugi čvor, što ujedno znači i brže širenje informacija
Betweenness	Uloga pojedinog čvora kao posrednika između drugih entiteta, točnije kontrola koju čvor ima nad interakcijom drugih
Eigenvector	Mjera pokazuje važnost pojedinog čvora na način da on ne mora imati nužno veliki broj veza da bi bio važan, već i manji broj ako je povezan s čvorovima koji imaju velik broj veza pa samim time preuzima dio njihovog utjecaja
PageRank	Varijanta <i>Eigenvectora</i> koji u obzir uzima i težinu veza između čvorova (različite veze imaju različiti stupanj važnosti odnosno pondere) ¹⁶

Tablica 2.3.1 - Opis mjera centraliteta na razini pojedinačnih entiteta

Analiza na razini podgrupe razmatra takozvane kohezivne podgrupe mreže korištenjem različitih vrsta tehnika (npr. komponente i klike).¹⁷ To znači da su dijelovi mreže povezani više ili manje, a softver koji će biti upotrijebljen u nastavku (Gephi) koristi *modularity* izvještaj koji u pozadini vrti algoritam temeljen na tzv. *Louvain Method* načinu izračuna.^{18, 19} Takvi postupci nam pomažu u prikazivanju pojedinih komponenata (klastera) neke mreže.

¹⁴ KOPAL, R., KORKUT, D., KRNJASIĆ, S. *Analiza (socijalnih) mreža: praktična primjena*. Zagreb: IN2data d.o.o. / Visoko učilište Algebra, 2016., str. 87.

¹⁵ KOPAL, R., KORKUT, D., KRNJASIĆ, S. *Analiza (socijalnih) mreža: praktična primjena*. Zagreb: IN2data d.o.o., Visoko učilište Algebra, 2016., str. 88-94.

¹⁶ Cambridge Intelligence. *EigenCentrality & PageRank*.

<https://cambridge-intelligence.com/eigencentrality-pagerank/> (04.01.2018.)

¹⁷ DE NOOY, W., MRVAR, A., BATAGELJ, V. *Exploratory Social Network Analysis with Pajek (Structural Analysis in the Social Sciences)*. Cambridge: Cambridge University Press, Kindle Edition, 2011., str. 71.

¹⁸ Github. *Modularity Algorithm*.

<https://github.com/gephi/gephi/wiki/Modularity> (04.01.2018.)

¹⁹ Google Sites. *Louvain Method: Finding communities in large networks*. <https://sites.google.com/site/findcommunities/> (04.01.2018.)

Što se tiče mjere koja se odnosi na mrežu u cjelini jedna od najpoznatijih je gustoća, odnosno omjer zbroja svih postojećih veza s brojem mogućih veza.²⁰

Izrazito je bitno shvatiti kontekst u sklopu kojeg određena mreža egzistira te relevantnost pojedinih izračuna jer ono što vrijedi za jednu mrežu ne vrijedi za drugu. Tako primjerice određivanje važnosti *node-ova* prema određenoj metrici može biti potpuno nevažno ako nismo upućeni u karakteristike okoline u sklopu koje se mreža nalazi.

Tako govoreći, ranije je navedeno da upravljanje tijekom informacija predstavlja glavnih cilj ovog rada. Bez obzira da li smo mi ti koji plasiramo informacije ili želimo spoznati procese koji kreiraju drugi, upravo utvrđivanjem različitih metrika možemo stjeći prednost pred drugima. Time propagiranje naših poruka može postati efikasnije, dok oponentima isto možemo otežati.

Budući da kompleksne mreže mogu imati izrazito veliki broj *node-ova* i veza, a matematički izračuni u smislu prikaza postati posve nepregledni čak i prilikom korištenja ekrana visoke rezolucije, često se pribjegava korištenju vizualizacijskih tehnika koje pomažu u interpretaciji podataka i njihovom razumljivijem shvaćanju. U nastavku će se stoga poseban dio izdvojiti na to kako bi se naglasila važnost korištenja vizualizacijskih tehnika u sklopu SNA analize.

²⁰ KOPAL, R., KORKUT, D., KRNJASIĆ, S. *Analiza (socijalnih) mreža: praktična primjena*. Zagreb: IN2data d.o.o. / Visoko učilište Algebra, 2016., str. 111.

2.4. Vizualizacija podataka

Jedno od glavnih pitanja ovog rada odnosi se upravo na svrhu prikazivanja podataka kroz vizualizacije. Bilo bi posve krivo zaključiti da proces vizualizacije nepotrebno produljuje analitički proces, posebice ako uzmemo u obzir da velik broj različitih programskih i infrastrukturnih rješenja ima izrazito značajne mogućnosti u smislu obrade podataka. Međutim, upravo u tome i leži problem jer tradicionalni softveri često baziraju svoj output na pružanju informacija, a ne njihovom shvaćanju.²¹ Tako gledano, klasični tablični prikazi su daleko inferiorniji spram grafičkih, posebice u smislu prezentacije velikih količina podataka koji se danas generiraju svuda oko nas.²²

Osim tih prednosti poznati stručnjak za vizualizaciju podataka Stephen Few navodi da su vizualizacije ključne zbog činjenice da olakšavaju spoznaju, odnosno osnažuju kogniciju.²³ U tom smislu ističe da interakcija i pregledavanje podatka kroz vizualizacije povećava naše shvaćanje teme jer mozak puno lakše percipira grafičke oblike nego pisane simbole poput slova i brojki te ujedno pomaže da počnemo sveobuhvatnije razmišljati o informacijama.

Takve pretpostavke temelje se također i na činjenici da je ljudsko oko prirodno utrenirano da uočava uzorke, a slijedom toga grafička prezentacija SNA analize svoje izvorište ima u matematičkoj teoriji grafova, točnije sociogramu koji na grafički način prikazuje strukturu veza između *node-ova* (točnije entiteta, odnosno u promatranom slučaju, ljudi).²⁴

Općenito govoreći razlikujemo temeljnu podjelu vizualizacija prema tipu podataka, a to su 1-, 2- i 3-dimenzionalni podaci, n-dimenzionalni, vremenski, hijerarhijski (stabla) i mreže²⁵. Nastavno na SNA analizu bitno je istaknuti da su mreže jedan od

²¹ FEW, S. *Now You See It*. Oakland, CA: Analytics Press, 2009., str. 3.

²² FEW, S. *Now You See It*. Oakland, CA: Analytics Press, 2009., str. 3.

²³ FEW, S. *Now You See It*. Oakland, CA: Analytics Press, 2009., str. 13.

²⁴ DE NOOY, W., MRVAR, A., BATAGELJ, V. *Exploratory Social Network Analysis with Pajek (Structural Analysis in the Social Sciences)*. Cambridge: Cambridge University Press, Kindle Edition, 2011., str. 17.

²⁵ [16] SHNEIDERMAN, B. *The Eyes Have It: A Task By Data Type Taxonomy For Information Visualizations*. Los Alamitos, CA: IEEE Computer Society Press, IEEE Symposium on Visual Languages, 336-343, 1996., str. 337.

primjera mnogobrojnih vrsta vizualizacija pa će ovaj rad počivati upravo na grafičkom prikazu različitih mreža.

Kao i na početku poglavlja kada je postavljeno pitanje o svrhovitosti vizualizacija kao takvih, u slučaju vizualizacije mreža također se možemo slično zapitati. Zašto zapravo koristimo vizualizacije kod provođenja SNA analize i da li takav postupak zaista potreban? Nakon izračuna metrika na razini pojedinačnih *node-ova*, kao i na razini cjelokupne mreže, grafički prikaz mreže temeljen na takvim izračunima uvelike nam može pomoći u potpunijem shvaćanju oblika i veličine mreže, kao i u uočavanju klastera te ključnih lokacija koje čine povezani entiteti.²⁶ Budući da je pozicija i važnost *node-a* u odnosu na druge *node-ove* jedno od glavnih pitanja SNA analize²⁷ upravo je putem grafičkih prikaza lakše ukazati na takve relacije.

Zaključno, vizualizacije nisu same sebi svrhom već počivaju na ideji da nam omogućuju učinkovitiji i lakši proces zaključivanja kroz istraživanje i vizualno uspoređivanje kvantitativnih vrijednosti odnosno pojedinačnih podataka.²⁸ To u konačnici dovodi do značajnijeg pomaka u podlogama koje se koriste pri donošenju odluka i finalni rezultati rada počivati će upravo na tim premisama.

²⁶ HANSEN, D., SHNEIDERMAN, B., SMITH, M. *Analyzing Social Media Networks with NodeXL*. Burlington, MA: Morgan Kaufmann, Kindle Edition, 2011., str. 5.

²⁷ HANSEN, D., SHNEIDERMAN, B., SMITH, M. *Analyzing Social Media Networks with NodeXL*. Burlington, MA: Morgan Kaufmann, Kindle Edition, 2011., str. 32.

²⁸ FEW, S. *Now You See It*. Oakland, CA: Analytics Press, 2009., str. 53.

3. Područje analize

3.1. Eksplorativna analiza i njezine značajke

Proces vizualizacije podataka (baš kao i postupak SNA analize) generalno se može (između ostalog) podijeliti na istraživačku (eksplorativnu) te usmjerenu analizu²⁹. Pri tome usmjerenu karakterizira postavljanje hipoteza i posljedično potvrđivanje ili odbacivanje, odnosno cijeli postupak počinjemo pitanjem na koje želimo dati odgovor. Suprotno navedenom, istraživačku analizu karakterizira proučavanje podataka bez unaprijed postavljenog pitanja.

Ako u kontekstu ovog rada promatramo prirodu provođenja SNA analize i posljedične vizualizacije podataka bitno je istaknuti da ne pretpostavljamo nikakve konkretne hipoteze te stoga možemo reći da će se ovdje raditi upravo o istraživačkoj analizi. Budući da su statistički modeli za izračun i testiranje hipoteza u sklopu SNA analize izrazito kompleksni³⁰ i još uvijek nedovoljno razvijeni fokus će primarno biti stavljen na spomenutu eksplorativnu analizu. Pojednostavljeno, kod SNA analize nećemo koristiti metode induktivne statistike, odnosno donošenja zaključaka o općoj populaciji temeljem uzoraka budući da strukturna obilježja mrežnog uzorka rijetko kada odražavaju strukturu kompletne mreže.³¹ Ovaj rad je stoga baziran na istraživanju i utvrđivanju karakterističnih obilježja mreže koja nam mogu donijeti novo znanje u smislu donošenja potencijalno važnih zaključaka koje možemo primijeniti za djelovanje u informacijskom prostoru. Bitno je poštovati redoslijedna pravila koja se vežu uz takav proces budući da za ostvarivanje rezultata moramo stvoriti i određene preduvjete koji proizlaze iz prethodnih koraka takvog procesa. To podrazumijeva da postupak biva točno određen.

²⁹ KUNIĆ, Z. *Vizualizacijski softverski alati u marketingu: Analitička navigacija*, 6. predavanje. Zagreb: Visoko učilište Algebra, 2017., str. 4.

³⁰ DE NOOY, W., MRVAR, A., BATAGELJ, V. *Exploratory Social Network Analysis with Pajek (Structural Analysis in the Social Sciences)*. Cambridge: Cambridge University Press, Kindle Edition, 2011., str. 5-6.

³¹ DE NOOY, W., MRVAR, A., BATAGELJ, V. *Exploratory Social Network Analysis with Pajek (Structural Analysis in the Social Sciences)*. Cambridge: Cambridge University Press, Kindle Edition, 2011., str. 6.

U tom smislu proces istraživačke SNA analiza sastoji se od četiri dijela³²:

1. definicije mreže,
2. manipulacije mreže,
3. izračunu metrika (definiranju strukturnih obilježja) i
4. vizualizaciji.

Sličan proces će se upravo provoditi kroz cijeli ovaj rad, a sve kako bi u konačnici što učinkovitije mogli provesti posljednji korak, vizualizaciju samih mreža.

U nastavku će bit definiran početni korak, tj. provođenje postupka definicije mreže kroz pristupanje podacima na Facebooku. Kako uvjeti (specifikacije) pod kojima mreža egzistira može uvelike utjecati na strukturu bitno je jasno definirati kriterije po kojima određeni entiteti ulaze u istu ili ne.³³

³² DE NOOY, W., MRVAR, A., BATAGELJ, V. *Exploratory Social Network Analysis with Pajek (Structural Analysis in the Social Sciences)*. Cambridge: Cambridge University Press, Kindle Edition, 2011., str. 6.

³³ DE NOOY, W., MRVAR, A., BATAGELJ, V. *Exploratory Social Network Analysis with Pajek (Structural Analysis in the Social Sciences)*. Cambridge: Cambridge University Press, Kindle Edition, 2011., str. 6.

3.2. Informacijsko ratovanje kao alat za ostvarivanje interesnih ciljeva

Društvene mreže su u okvirima ovog rada odabrane kao predmet proučavanja zbog njihove sposobnosti da apsorbiraju i šire informacije izrazito velikom brzinom. Definiranjem temeljnih pojmova također je pokazano kako će glavni fokus istraživanja biti usmjeren na primjenu različitih analitičkih metoda kojima će se pokušati razjasniti kontekst u kojem se odvijaju procesi u određenim segmentima informacijskog prostora na Facebooku.

U vezi s time posebice je naglašena uloga informacijskog ratovanja, međutim do sad je taj pojam bio definiran na izrazito općenit način, a da bi detaljnije razradili tematiku koja će biti istražena u nastavku dodatna elaboracija kroz primjere je neophodna.

Gledajući trenutačne ekonomske i političke odnose na makro razini Europske unije izrazito je aktualno pitanje ruskog utjecaja u sferi medijske manipulacije, a koja je vezana uz ekonomski rast te velesile koja ponovno vraća dio snage izgubljene nakon raspada Sovjetskog saveza. Tako možemo zamijetiti niz inicijativa i poteza kojima se namjerava suzbiti strategija propagiranja ruske verzije „istine“, a valja naglasiti da u zadnje vrijeme i Republika Hrvatska postaje sve aktivniji po tom pitanju. Europska služba za vanjsko djelovanje (EEAS) osnovala je Strategic Communications Division (StratCom) kako bi što učinkovitije parirala različitim dezinformacijama koje se plasiraju kroz medijski prostor članica EU, a svojim je diplomacijom i Hrvatska podržava navedenu inicijativu.^{34, 35}

Jedan od primjera na razini EU jest također i Istočno partnerstvo koje je posebno fokusirano na zemlje koje su potencijalni kandidati za pristupanju EU poput Ukrajine.

³⁴ Jutarnji list. *Putinov hibridni rat: i Hrvatska traži pomoć EU u suzbijanju ruske propagande*. <https://www.jutarnji.hr/vijesti/hrvatska/putinov-hibridni-rat-i-hrvatska-trazi-pomoc-eu-u-suzbijanju-ruske-propagande-suoceni-smo-s-velikom-i-vrlo-sofisticiranom-kampanjom-dezinformiranja/6678054/> (13.12.2017.)

³⁵ European External Action Service (EEAS). *Strategic Communications Division (StratCom)*. https://eeas.europa.eu/headquarters/headquarters-homepage_en/100/Strategic%20Communications (13.12.2017.)

U nizu rasprava i bilateralnih susreta višestruko je istaknuta važnost borbe koja bi trebala doprinijeti neutraliziranju utjecaja ruskih dezinformacijskih aktivnosti.³⁶

Gledajući navedeno u kontekstu američkih predsjedničkih izbora krajem 2016. godine moguće je izdvojiti nekoliko pojmova koji se direktno naslanjaju na dezinformacijske aktivnosti. Tako je primjerice fraza „lažne vijesti“ (eng. *fake news*) proglašena kao najpopularnija riječ u 2017. godine od strane poznatog engleskog rječnika Collins. Pri tome pojam označava lažne, često senzacionalne vijesti koje se šire pod okriljem regularnih medijskih novosti³⁷, a pojam je popularizirao upravo aktualni američki predsjednik Donald Trump. Nastavno na to, upravo je popularizacija tzv. *troll-ova* (eng. *troll*) i *bot-ova* (eng. *bot*) doprinijela širenju dezinformacija tijekom navedenih predsjedničkih izbora³⁸, posebice putem društvenih mreža. Pod istima podrazumijevamo ljudski upravljene (*troll*)³⁹ i automatizirane (*bot*)⁴⁰ profile koji svojim aktivnostima šire određenu agendu, najčešće primjerice širenjem lažnih vijesti ili zastupanjem određenih interesa.

Sve do sad spomenuto ne samo da služi pukom ostvarivanju ciljeva različitih država ili interesnih skupina već se navedeno isto tako može promatrati u kontekstu geopolitičkih poteza. Navedeni procesi ne moraju nužno biti sami sebi svrhom već mogu predstavljati indirektno djelovanje na neke sasvim druge ciljeve koje se posredno mogu ispuniti upravo putem takvog informacijskog utjecaja. Slično potvrđuje i Ministar unutarnjih poslova Republike Hrvatske dr.sc. Davor Božinović koji u recentnim medijskim istupima često naglašava važnost zaštite državnih interesa. Prema njegovim riječima „...danas je u prvom planu internet, dakle društvene mreže koje se, uz sve ono dobro što su donijele i što nose za razvoj društva, koriste i kako bi se plasirale različite dezinformacije, lažne informacije, lažne vijesti s ciljem da se progura određeni interes koji nužno ne mora biti nacionalni

³⁶ Eastern Partnership Civil Society Forum (EaP CSF). *Eastern Partnership: Battleground of Russia's Disinformation War*.

<https://eap-csf.eu/eastern-partnership-battleground-of-russias-disinformation-war/> (14.12.2017.)

³⁷ Collins Dictionary. *The Collins Word of the Year 2017 is...*

<https://www.collinsdictionary.com/woty> (08.02.2018.)

³⁸ The Guardian. *How Russia used social media to divide Americans*.

<https://www.theguardian.com/us-news/2017/oct/14/russia-us-politics-social-media-facebook> (08.02.2018.)

³⁹ Techopedia. *What is a Troll?*

<https://www.techopedia.com/definition/429/troll> (09.02.2018.)

⁴⁰ Techopedia. *What is a Socialbot?*

<https://www.techopedia.com/definition/27811/socialbot> (08.02.2018.)

interes zemlje u kojoj se to zbiva.“⁴¹ Ono što je najbitnije za istaknuti jest da finalni efekti potencijalno mogu predstavljati ugrozu za opstojnost države, njezinih institucija te izazvati šire društvene, političke i ekonomske nestabilnosti. U najgorem mogućem scenariju to su svakako demonstracije i ratovi.

Ako govorimo o zbivanjima u svijetu možemo istaknuti nemire u Turskoj, konkretnije događaje koji su započeli na istambulskom trgu Taksim tijekom 2013. godine, ali su u konačnici bili uspješno ugušeni od strane državnog represivnog aparata. S druge strane posljedice tzv. „Arapskog proljeća“ osjećaju se dan danas. Niz društvenih nemira započetih 2010. na području sjeverne Afrike i Bliskog istoka rezultirao je u ratovima koji još uvijek traju, posebice onaj na području Sirije.

Želimo li se svesti u lokalne okvire odličan primjer za to su i različiti društveni prosvjedi koji su se u recentnoj prošlosti odvijali na području Republike Hrvatske, a koji su organizirani od strane različitih nezavisnih, neformalnih i/ili neprofitnih organizacija. Dva istaknutija događaja su svakako prosvjedi hrvatskih branitelja u Savskoj ulici u Zagrebu te prosvjedi za kurikularnu reformu na Trgu bana Josipa Jelačića, također u glavnom gradu Republike Hrvatske.

Prosvjedi velikog broja braniteljskih udruga trajali su čak 555 dana, od listopada 2014. do travnja 2016. godine i bili medijski izrazito popraćeni zbog političkog konteksta i čestog kritiziranja tadašnje SDP-ove vlade.⁴² S druge strane za vrijeme HDZ-ove vlade pokrenuta je inicijativa „Hrvatska može bolje“ koja je organizirala niz demonstracija od kojih su najmasovnije bile one 1. lipnja 2016. i 2017. godine. Kao koordinatori inicijative navedene su nezavisne i neprofitne udruge poput „Forum za slobodu odgoja“, „Centar za mirovne studije“, „GONG“, „Mreža mladih Hrvatske“, „Kurziv“, itd.⁴³

Takvi i slični događaji nisu izolirani niti specifični za Hrvatsku te u svijetu više predstavljaju pravilo, nego iznimku. Budući da potencijalni efekti koje proizvode

⁴¹ Jutarnji list. *Intervju s ministrom unutarnjih poslova dr. sc. Davorom Božinovićem*.
<https://www.jutarnji.hr/vijesti/hrvatska/bozinovic-plenkovic-voj-oporbi-u-hdz-u-prije-njega-nismo-mogli-realizirati-vec-dobivenu-izbornu-bitku-a-i-na-vlasti-smo-trajali-koliko-smo-trajali/6888870/>
(19.01.2018.)

⁴² Nova TV. *Završen braniteljski prosvjed u Savskoj*.
<https://dnevnik.hr/vijesti/hrvatska/završen-braniteljski-prosvjed-u-savskoj---434862.html> (14.12.2017.)

⁴³ Hrvatska može bolje. *Tko podržava ovu inicijativu?*
<http://hrvatskamozebolje.org/tko-podrzava-ovu-inicijativu> (12.12.2017.)

moгу neupitno dovesti do razliĉitih promjena unutar teritorija jedne drŹave (i Źire), pravovremeno uoĉavanje te proaktivno upravljanje tokom informacija kojima se isti potiu svakako moŹe doprinijeti do veće kontrole nad takvim procesima.

Na takvim pretpostavkama u dijelu analize temelji se i ovaj rad, konkretno u vidu prepoznavanja obrazaca plasiranja informacija na druŹtvenim mreŹama koje su se tijekom većine navedenih prosvjeda obilato koristile u smislu stvaranja odreĊenog mijenja javnosti o danoj temi.

Kako bi se osigurala maksimalna nepristranost i balans, entiteti koji će u nastavku predstavljat predmet prouĉavanja biti će podijeljeni u tri grupe, od kojih su dvije po znaĉaju najbitnije - jedna koja je u druŹtvenom i politiĉkom kontekstu bliŹa ljevici (liberalnije druŹtvene struje) te druga koja je bliŹa desnici (konzervativna strujanja). Takva podjela se upravo naslanja na nedavne znaĉajnije prosvjede u Republici Hrvatskoj koji su spomenuti u prethodnim odlomcima te ujedno predstavljaju jedan od povoda za vršenje ove analize. Kako su navedeni dogaĊaji bili politiĉki suprotnog pola, tako će se formirati i ova analiza.

Podskupine te tri generalne grupe ĉine razliĉite interesne organizacije - udruge, mediji, istaknute javne osobe, politiĉke stranke i tome sliĉno. U tom kontekstu vaŹno je napomenuti da su iz analize namjerno izostavljeni veliki *mainstream* mediji kojima upravlja privatni kapital, velike politiĉke stranke te da se naglasak stavio upravo na niz manjih aktera koji se najĉešće proklamiraju kao nezavisni i neprofitni te nisu nuŹno istureni u javnosti, ali imaju znaĉajan utjecaj.

Razlog tome leŹi upravo u ĉinjenici da njihovoj djelovanje najĉešće ne moŹe biti ĉak niti djelomiĉno prikriveno u smislu opsega i ciljeva kao Źto je to npr. sluĉaj s velikim medijima. Sama ĉinjenica da njihova egzistencija ovisi o donacijama od strane drŹave ili privatnog sektora ĉini ih dovoljno podloŹnima utjecajima od strane vanjskih ĉimbenika pa se pod tom pretpostavkom njihovo proklamirano „nezavisno“ djelovanje moŹe smatrati u najmanju ruku upitnim. Njihova meĊusobna povezanost tada je posljediĉno zanimljiv predmet analize kako bi shvatili potencijal Źirenja informacija.

U tom kontekstu moŹemo razmotriti joŹ neke druŹtvene i politiĉke specifikume Republike Hrvatske koje navedenim pretpostavkama daju dodatnu snagu. Osim

spomenutih javnih prosvjeda koji predstavljaju disruptivni faktor za državu, u medijima se često potencira štetnost financiranja religijskih zajednica iz državnog proračuna, prije svega Katoličke crkve. Prema navodima Vlade Republike Hrvatske ista je u razdoblju 2014 - 2016. zaprimila 1.06 milijardi kuna proračunskog novca.⁴⁴ S druge strane za djelovanje takozvanih organizacija civilnog društva iz proračuna Republike Hrvatske i fondova EU osigurano je također preko milijardu kuna i to samo u 2017. godini.⁴⁵ Velik broj interesnih entiteta navedenih u prethodnom poglavlju potpada pod organizacije koje promoviraju ideje katoličanstva i bliske su crkvi, međutim još je veći broj onih koji spadaju pod organizacije civilnog društva.

Moć raznih organizacija u smislu propagiranja informacija i ostvarivanja različitih interesa direktno se naslanja na opisanu potentnost u pogledu stjecanja značajnih količina kapitala. Pri tome valja naglasiti da izvor novčanih donacija nije samo državni proračun, već i privatni sektor, a nerijetko i inozemni kapital (također privatni i državni) što pomaže staviti njihovo djelovanje u određeni kontekst.

Kao što je već više puta istaknuto, analiza informacijskih procesa gore opisanih entiteta biti će učinjena upravo putem vizualizacija koje će se temeljiti na SNA analizi javno dostupnih podataka o aktivnostima odabranih Facebook stranica.

⁴⁴ Vlada Republike Hrvatske. *Financiranje vjerskih zajednica u Republici Hrvatskoj - odgovor na zastupničko pitanje Anke Mrak - Taritaš*.
<https://vlada.gov.hr/UserDocsImages//Sjednice/2017/12%20prosinac/70%20sjednica%20VRH//70%20-%2023%20a.pdf> (19.01.2018.)

⁴⁵ Vlada Republike Hrvatske. *Godišnji plan natjecaja tijela državne uprave za 2017. godinu*.
<https://udruga.gov.hr/godisnji-plan-natjecaja-javnih-poziva-i-drugih-programa-financiranja-projekata-i-programa-organizacija-civilnog-drustva-u-2017-godini/4004> (19.01.2018.)

3.3. Komunikacija putem socijalnih mreža

U uvodnom dijelu je rečeno da upravo društvene mreže zbog svoje opće prihvaćenosti i dinamičnosti predstavljaju savršeni poligon za komuniciranje pa tako i vršenje različitih analiza tih komunikacija. S tim u vezi, predstavljaju i idealni teren za širenje interesne propagande. U usporedbi s Twitterom koji na području Republike Hrvatske koristi manje od 100 tisuća ljudi, Facebook broji daleko najviše korisnika (minimalno njih 1,5 milijuna) pa se može smatrati najrelevantnijim za potencijalno istraživanje.⁴⁶ Suprotno trendovima u Hrvatskoj broj korisnika Twittera u Sjedinjenim Američkim Državama je neusporedivo veći pa bi analiza Twitter komunikacija kakva se vrši u ovom radu u tom slučaju bila puno svrsishodnija. Razlog tome ne leži isključivo u apsolutnom broju korisnika, već i u samoj prirodi funkcioniranja te društvene mreže. Osim kratke forme Twitter objava koje su pogodne za brzo širenje vijesti sučelje koje omogućuje javni pristup sustavu, tzv. Twitter API (eng. *Application Programming Interface*)⁴⁷, za razliku od Facebooka ne onemogućava automatizirane profile (spomenute *bot-ove*).⁴⁸ Kako su *botovi* često korišteni u različitim sferama informacijskog ratovanja upravo bi Twitter podaci bili izrazito zanimljivi za analizu.

Važnost analize koja se provodi u sklopu ovog rada potvrđena je između ostalog i za vrijeme same izrade. Serija događaja koji nipošto nisu zanemarivi i bacaju zanimljivo svjetlo na istraživački proces desila se upravo početkom prosinca 2017. Nakon samoubojstva hrvatskog general pukovnika Slobodana Praljka dogodio se niz masovnih prijava usmjeren protiv različitih domaćih Facebook stranica, profila i objava. Navedeno se u smislu sadržaja najčešće odnosilo na objave koje su govorile ili pozitivno ili negativno o spomenutom generalu. Tako su Facebook stranice lijeve političke orijentacije osuđivale, a desne glorificirale djelovanje Slobodana Praljka. Masovne prijave korisnika dovele su do privremene ili trajne blokade cijelog niza stranica pri čemu kao primjer možemo navesti stranice „Antifa Šibenik“, „Antifa

⁴⁶ The Dubrovnik Times. *The social media scene in Croatia in 2018. - Facebook dominates, Instagram rising, Twitter still locked its cage.* <http://www.thedubrovniktimes.com/lifestyle/feature/item/3854-the-social-media-scene-in-croatia-in-2018-facebook-dominates-instagram-rising-twitter-still-locked-its-cage> (09.02.2018.)

⁴⁷ Twitter Developers. *Twitter Developer Platform.* <https://developer.twitter.com/> (09.02.2018.)

⁴⁸ Science Magazine. *Social media 'bots' tried to influence the U.S. election. Germany may be next.* <http://www.sciencemag.org/news/2017/09/social-media-bots-tried-influence-us-election-germany-may-be-next> (09.02.2018.)

Zagreb“ i „Antifašistički vjesnik“ ili pak objave sadržaja na pojedinim profilima (npr. kolumna Ive Lučića za Večernji list).⁴⁹

Kako bi razlučili mogućnosti koje nam stoje na raspolaganju u smislu analize potrebno je definirati osnovnu podjelu vrste entiteta na Facebooku te posljedično kakvi tipovi podataka bivaju javni, a koji privatni.

Primarno je potrebno razlikovati tri osnovne vrste entiteta, a to su redom osobni profili korisnika⁵⁰, *fan pages*⁵¹ (u daljnjem tekstu stranice) te grupe.⁵² Pri tome grupe služe za rasprave individualnih korisnika o nekim zadanim temama, a stranice predstavljaju različite organizacije, poslovne subjekte, brendove i tome slično.

U pogledu privatnosti, različita ograničenja koja nameće Facebook API, punog naziva The Graph API⁵³, bivaju odlučujućima u smislu odabira koje podatke možemo prikupiti, odnosno analizirati, a koje ne. The Graph API omogućuje trećim stranama povezivanje i pristupanje sustavu pa tako i povlačenje podataka od interesa, a o čemu će kasnije biti riječ.

Osobni profili i stranice dijele neke zajedničke značajke u smislu kreiranja sadržaja, prije svega komentiranja i dijeljenja no ako ih gledamo kroz prizmu entiteta i veza, veze između profila su neusmjerene (prijateljstva), između profila i stranica usmjerene (isključivo prema stranicama) te između stranica usmjerene (ovisno da li stranica slijedi neku drugu stranicu). Navedene stavke predstavljaju osnovnu razinu analize koja se može nadograđivati u različitim smjerovima, posebice u smislu osnovnog modela na kojem se zasnivaju veze. Tako možemo razrađivati i povezanost između profila temeljem komentara, *like-ova* (eng. *like*), dijeljenja sadržaja, itd. - sve zavisno o kontekstu i cilju analize. Pri tome valja napomenuti da

⁴⁹ RTL Televizija. "Rat" na Facebooku: blokirani desničari koji veličaju generala Praljka - odgovorili prijavama protiv ljevičara pa mreža blokirala i njih.

<https://vijesti.rtl.hr/novosti/hrvatska/2754735/rat-na-facebooku-blokirani-desnicari-koji-velicaju-general-praljka-odgovorili-prijavama-protiv-ljevicara-pa-mreza-blokirala-i-njih/> (19.01.2018.)

⁵⁰ Facebook Help Center. *Your Profile and Settings*.

<https://www.facebook.com/help/239070709801747> (04.12.2017.)

⁵¹ Facebook Help Center. *Pages*.

<https://www.facebook.com/help/282489752085908> (04.12.2017.)

⁵² Facebook Help Center. *Groups*.

<https://www.facebook.com/help/1629740080681586> (04.12.2017.)

⁵³ Facebook For Developers. *The Graph API*.

<https://developers.facebook.com/docs/graph-api> (04.12.2017.)

like-ovi podrazumijevaju označavanje objavljenog sadržaja ovisno o vrsti emocije koju korisnik odabere za dani sadržaj (npr. *like*, *love*, *sad*, itd.).⁵⁴

U pogledu ovog rada primarni fokus određuje navedena javna dostupnost podataka. Kako je kontekst u kojem djeluju stranice primarno javnog karaktera, razina dostupnosti podataka o istima je kudikamo veća u odnosu na informacije koje se mogu obuhvatiti za osobne profile. Tako rečeno, moguće je obuhvatiti i podatke o tome koje stranice slijedi neka stranica što će ujedno činiti bazu ovog modela.

⁵⁴ Facebook Help Center. *Liking & Reacting*.
<https://www.facebook.com/help/452446998120360/> (09.02.2018.)

4. Strukturiranje podataka prema pretpostavljenom modelu mreže

4.1. Razvoj osnovnog modela mreže

Od krucijalne je važnosti napomenuti da se nad mrežama uvijek može provoditi identičan skup izračuna koji podrazumijeva korištenje numeričkih informacijama o entitetima i vezama no bitno je razlučiti kontekst osnovne konstrukcije te posljedičnog djelovanja, odnosno „života“ same mreže.

Uvjeti u kojima mreža egzistira specifičan je za svaki pojedini slučaj pa tako i za društvene mreže poput Facebooka. U prethodnom poglavlju su naglašene mreže koje egzistiraju temeljem usmjerenih veza između stranica te će iste činiti primarni dio analize. Osnovni model će pretpostavljati upravo takvu mrežu koja je zatvorena te nema doticaja s nikakvim drugim tipom entiteta.


Takva pretpostavka se bazira upravo na dostupnosti javnih podataka koji onemogućuju analize van takvog okvira što je ujedno i značajno ograničavajući faktor. Osim tehničkih ograničenja ovaj rad je izveden u uvjetima (već spomenutih) ograničenih budžetnih resursa pa pretpostavlja izradu modela koji uz male preinake može funkcionirati i ako se primjeni na mrežu koje ne čine samo stranice, već i osobni profili te grupe. Kako bi shvatili način funkcioniranja stranica i prenošenja informacija u takvoj mreži možemo pretpostaviti da jedna stranica slijedi drugu u dva uvjeta:

1. zbog afiniteta prema sadržaju,
2. zbog želje za primanjem informacija, neovisno o afinitetu.

Ako pretpostavimo zatvorenost takvog sustava, odnosno mreže, priljev informacija nije moguć izvana što predstavlja pojednostavljeni osnovni model za provođenje analiza. Budući da u stvarnosti administratori stranica informacije mogu primati i van navedenih uvjeta (npr. dobivanje i dijeljenje sadržaja na stranicu kroz osobni profil ili dijeljenje sadržaja dobivenog izvan društvene mreže) točnost modela bi se uvelike povećala takvom nadogradnjom i dala preciznije rezultate primjenom sličnih ili identičnih tehnika analize.

U tom smislu po mišljenju autora ovog rada možemo razlučiti nekoliko razina nadogradnje osnovnog modela. Konceptualno se to može kretati u dva smjera na sljedeći način:

1. izdvojeni model u sklopu kojeg mrežu čine *node-ovi* koji su isključivo osobni profili (od interesa) te koji nisu toliko pod utjecajem pada organskog dosega poput stranica. Takvom analizom bi lakše predvidjeli širenje informacija između profila bez obzira da li je ista stigla izvan mreže ili je kreirana unutar mreže;




Slika 4.1.1 - Model koji sadrži samo međusobno povezane profile

2. nadogradnja osnovnog (postojećeg) modela koji već sadrži samo stranice. U tom pogledu kod osnovnog modela se analiziraju usmjerene veze između stranica (jednomodalna mreža - jedna vrsta entiteta).⁵⁵ Sljedeće razine nadogradnje bi bile:
(Nastavak je vidljiv na sljedećoj stranici)

⁵⁵ HANSEN, D., SHNEIDERMAN, B., SMITH, M. *Analyzing Social Media Networks with NodeXL*. Burlington, MA: Morgan Kaufmann, Kindle Edition, 2011., str. 36.


a) dodavanje profila, i to:

- profila koji slijede stranicu (usmjerena veza prema stranici) te informacije o međusobnoj povezanosti tih profila (neusmjerena međusobna veza), što predstavlja dvomodalnu mrežu (dvije vrste entiteta);




Slika 4.1.2 - Model koji sadrži profile koji slijede određene stranice i informacije o međusobnoj povezanosti tih profila

- profila koji su prijatelji s administratorima stranica (neusmjerena veza) te također njihova međusobna povezanost (isto neusmjerena konekcija), što također predstavlja dvomodalnu mrežu;



Slika 4.1.3 - Model koji sadrži stranice, administratore tih stranica i profile s kojima su administratori povezani

- b) dodavanje grupa u koje su učlanjeni profili uključeni na dosadašnjoj razini, ali i svih ostalih članova navedenih grupa i njihovih međusobnih veza, što predstavlja tromodalnu mrežu (tri vrste entiteta);



Slika 4.1.4 - Model koji sadrži profile, stranice i grupe te informacije o njihovoj međusobnoj povezanosti

- c) budući da organski doseg stranica pada i iznosi manje od 2%, broj *fan-ova* (osobe koje slijede određenu stranicu)⁵⁶ više nije toliko bitan, već sadržaj kojeg potencijalno oglašavamo putem oglašivačkog sustava.⁵⁷
- ⁵⁸ Ako oglašavanje podesimo na način da se naš sadržaj reklamira korisnicima koji imaju određene afinitete, navedeni nužno ne moraju slijediti našu stranicu. U tom pogledu trebalo bi provesti profiliranje koje bi nam govorilo koji su to ljudi koji bi najvjerojatnije mogli vidjeti naš oglas (oni bi bili članovi proširene mreže), a što je izrazito teško,
- d) model koji ima uključenu pretpostavku da pratimo medije putem posebnih softvera i zatim pratimo prelijevanje informacije s internet portala na društvene mreže (odnosno Facebook stranice tih portala).

⁵⁶ Facebook Help Center. *Like and Interact with Pages*.

<https://www.facebook.com/help/1771297453117418/> (09.02.2018.)

⁵⁷ Kissmetrics. *Do You Really Need More Facebook Likes? The Data Driven Answer*.

<https://blog.kissmetrics.com/facebook-likes-data-driven-answer> (06.12.2017.)

⁵⁸ Hubspot. *The Decline of Organic Facebook Reach & How to Outsmart the Algorithm*.

<https://blog.hubspot.com/marketing/facebook-declining-organic-reach> (06.12.2017.)

Neovisno o svemu, samo dodavanje osobnih profila (navedeno pod točkom a)) te provođenje analize nad dvomodalnom mrežom sačinjenom od usmjerenih i neusmjerenih veza uvelike bi povećalo točnost predviđanja prijenosa informacija. Koji god model koristili trebalo bi provesti ponderiranje te međusobnu usporedbu istih kako bi uvidjeli razlike u točnosti predviđanja svakog.

Bez obzira na navedeno, osnovni model baziran isključivo na stranicama poslužiti će kao odličan primjer za prikazivanje načina na koji možemo provesti SNA analizu u većini predloženih slučajeva te još bitnije - kvalitetno i sažeto vizualizirati dobivene rezultate.

4.2. Kontekstualizacija osnovnog modela

Prije samog povlačenja podataka i posljedične obrade bilo je potrebno razraditi koncept prema kojem će stranice biti grupirane (strukturirane) u skladu s ranije izrečenim pretpostavkama koje se dotiču funkcioniranja Facebook stranica. U tom pogledu glavno načelo prema kojem se vodio takav postupak jest homofilija⁵⁹, odnosno povezivanje između *node-ova* temeljem njihove sličnosti što u konačnici direktno utječe i na strukturu same mreže. Iz tog razloga je bilo izrazito bitno grupirati stranice sličnih obilježja pri čemu valja naglasiti da je korišteno načelo homofilije iz aspekta nominalnih karakteristika, ne numeričkih.⁶⁰ Pojedina literatura se u tom aspektu naslanja i na tzv. *topic centric* mreže⁶¹, odnosno one mreže čije su veze između čvorova temelje na određenim temama (npr. povezivanje Twitter profila temeljem korištenja identičnih *hashtag* oznaka u objavama).

Također, kad govorimo o povezivanju različitih entiteta valja naglasiti da veze između njih ne moraju imati nužno istu važnost ili biti istog tipa, a što se u teoriji naziva težinom veze (eng. *weight*). U sklopu ovog modela sve veze imaju istu težinu, odnosno težinu koja iznosi 1,0 (jednako su važne).⁶²

Ranije je spomenuto da Facebook stranica slijedi drugu stranicu iz dva temeljna razloga, a onaj primarni nadovezuje se upravo i na homofiliju - stranice međusobno slijede one stranice koje su im po tematici i interesima slične. Tim načelom je vođeno grupiranje egocentričnih mreža (stranica) - primjerice grupiranje udruga koje podržavaju zabranu pobačaja, formalno udruživanje interesnih organizacija (Platforma 112), različite medijske platforme (Mreža emancipacije E-net), itd. S teorijske strane bitno je definirati granice mreže jer ista direktno utječe i na samu

⁵⁹ KOPAL, R., KORKUT, D., KRNJAIŠIĆ, S. *Analiza (socijalnih) mreža: praktična primjena*. Zagreb: IN2data d.o.o. / Visoko učilište Algebra, 2016., str. 114.

⁶⁰ KOPAL, R., KORKUT, D., KRNJAIŠIĆ, S. *Analiza (socijalnih) mreža: praktična primjena*. Zagreb: IN2data d.o.o. / Visoko učilište Algebra, 2016., str. 116.

⁶¹ HANSEN, D., SHNEIDERMAN, B., SMITH, M. *Analyzing Social Media Networks with NodeXL*. Burlington, MA: Morgan Kaufmann, Kindle Edition, 2011., str. 36.

⁶² HANSEN, D., SHNEIDERMAN, B., SMITH, M. *Analyzing Social Media Networks with NodeXL*. Burlington, MA: Morgan Kaufmann, Kindle Edition, 2011., str. 34.

strukturu. Pri tome je naglašena važnost argumenata i kriterija koji definiraju samu mrežu što je u ovom slučaju izrazito bitno kod grupiranja egocentričnih mreža.⁶³

Kad se spomenu egocentrične (jednostupanjske) mreže⁶⁴ valja definirati da se radi o odabranoj Facebook stranici za koju su povučeni podaci o vezama koje ona ostvaruje prema drugim stranicama te su pri tome zanemarene sve ostale veze (npr. veze koje ostvaruju stranice koje slijedi ishodišna stranica - takozvana razina drugog stupanja). Kako bi se fokus zadržao upravo na analizi odabranih stranica namjerno nije odabrana opcija dodatnog širenja mreže na dvostupanjsku razinu, kao i zbog činjenice da se izbjegne kombinatorna eksplozija uslijedi prevelikog broja stranica. Međutim tako nešto bi definitivno bilo izvedivo i svrsishodno kad ne bi potpadalo pod budžetna i vremenska ograničenja koja su vezana uz ovaj rad.

Odabrane Facebook stranice su trebale zadovoljiti i neke druge karakteristike kao što su primjerice:

- zabilježena aktivnost i objava sadržaja u nedavnom razdoblju (izbjegavanje neaktivnih stranica),
- stranice koje koriste isključivo hrvatski jezik i primarno su orijentirane na domaću publiku (inozemne i regionalne stranice su zanemarene),
- bilo je poželjno da odabrana stranica slijedi druge stranice jer nema smisla analizirati *node-ove* koji ne sadrže usmjerene veze od samih sebe (primjerice određeni broj relativno popularnih stranica nije imao uopće ili nije imao puno takvih veza).

Ukupno su povučeni podaci za 146 ishodišne Facebook stranice te posljedično isto tako i podaci za stranice koje one slijede. U tom smislu radi se o 146 egocentrične mreže koje su podijeljene u tri osnovne grupe, a zatim grupirane u 15 podgrupa. Broj stranica ujedno odražava i opseg ovog rada te autor posljedično smatra isti dovoljnim da se omogući uočavanje generalnih trendova. Svakako je moguće analizirati njihov veći broj, ali se u tom smislu ponovno valja referencirati na ograničenja pod kojima je nastao ovaj rad, a ponajprije činjenicu da značajan broj

⁶³ DE NOOY, W., MRVAR, A., BATAGELJ, V. *Exploratory Social Network Analysis with Pajek (Structural Analysis in the Social Sciences)*. Cambridge: Cambridge University Press, Kindle Edition, 2011., str. 6.

⁶⁴ HANSEN, D., SHNEIDERMAN, B., SMITH, M. *Analyzing Social Media Networks with NodeXL*. Burlington, MA: Morgan Kaufmann, Kindle Edition, 2011., str. 36.

stranica nije zadovoljavao gore opisane uvjete (osim onih koje nisu imale odlazne veze postoji i niz onih u stanju mirovanja (npr. pokrenutih prilikom zadnjih parlamentarnih i predsjedničkih izbora u RH).

Kako bi analiza bila što nepristranija sukobljena su dva različita politička pola, a što se naslanja upravo na ranije opisane stavke u prethodnim poglavljima. Tako su dobivene tri osnovne skupine: grupacije koje koketiraju ili su bliske desnom (oznaka D) političkom spektru, odnosno lijevom (oznaka L), dok treću grupu čine nesvrstane stranice (oznaka N), a čine ju manifestacije te sindikati i savezi. Pri tome valja razlučiti da pod desnim političkim spektrom podrazumijevamo entitete koji zastupaju ideološke stavove poput domoljublja, ekonomskih sloboda te tradicionalnih vrijednosti kao što je pridodavanje značaja religiji i obitelji.⁶⁵ U kontekstu ovog rada i lijevog političkog spektra ističe se regulacija ekonomije od strane države i visoko oporezivanje, anti kapitalizam, civilna prava, multikulturalizam, smanjenje utjecaja religije i tome slično.⁶⁶

Načelno se proces strukturiranja odvijao u pet koraka prikazanih u tablici 4.1.1. Pri tome je svaka pojedina faza bila manje ili više zahtjevnost u smislu alokacije vremena potrebnog za izvršenje navedenih zadataka za svaku pojedinu Facebook stranicu od njih ukupno 146.

Korak	Opis	Opaske
1.	Odabir stranica prema kontekstu analize	Inicijalni korak u kojem je razmatran potencijal stranice za moguću analizu
2.	Zadovoljavanje osnovnih tehničkih karakteristika	Zabilježena recentna aktivnost, korištenje hrvatskog jezika, postojanje odlaznih veza, itd.
3.	Razvrstavanje u jednu od tri glavne grupe	Lakši dio procesa, klasificiranje stranica prema tematskom opredjeljenju
4.	Razvrstavanje u podgrupe	Grupiranje stranica prema zajedničkim karakteristikama, kompleksniji korak od prethodnog, bilo je potrebno posvetiti mnogo vremena detaljima
5.	Povlačenje i priprema podataka	Tehničko kreiranje mreže kao uvod u analizu i vizualizaciju podataka

Tablica 4.2.1 - Koraci u strukturiranju podataka prema zadanom modelu

⁶⁵ Wikipedia. *Right-wing politics*. https://en.wikipedia.org/wiki/Right-wing_politics (22.02.2018.)

⁶⁶ Wikipedia. *Left-wing politics*. https://en.wikipedia.org/wiki/Left-wing_politics (22.02.2018.)

Jednom kad su podaci strukturirani definiran je svojevrsan informacijski (medijski) prostor koji ujedno čini i glavno područje istraživanja. Takav informacijski prostor je podijeljen u tri grupe te spajanjem podgrupa stranica dobivamo mrežu koja predstavlja poligon za propagaciju informacija, odnosno vijesti. Valja napomenuti da u smislu istraživanja i analize navedene podgrupe stranica možemo koristiti u različitim kombinacijama, a što će biti pokazano u nastavku. Ukupni broj podgrupa je sljedeći: dvije za grupu s oznakom N, pet za grupu oznake D te osam za grupu oznake L. Gledajući s aspekta skupine koja se odnosi na lijevi politički spektar sakupljen je veći broj stranica iz jednostavnog razloga zato što su često aktivnije, brojnije te ih je lakše naći.

Valja istaknuti da je putem Facebook API-a dostupna informacija o ukupnom broju *fan-ova* pojedine stranice⁶⁷, dok *fan* može, ali i ne mora biti sljedbenik (eng. *follower*) te iste stranice, odnosno može ili ne mora biti izložen objavama stranice.

Naziv podgrupe	Broj stranica	Broj <i>fan-ova</i>
N - Manifestacije	3	27.539
N - Sindikati i savezi	3	13.131
UKUPNO N	6	40.670
D - Interesne organizacije - pro religijske	14	159.454
D - Mediji	10	354.434
D - Nezavisna propaganda	16	415.683
D - Osobe	4	174.761
D - Političke stranke	10	69.930
UKUPNO D	54	1.174.262
L - Interesne organizacije - anti religijske	11	59.579
L - Interesne organizacije - ostale	9	42.688
L - Interesne organizacije - ostale - Platforma 112	11	73.807
L - Mediji	11	117.638
L - Mediji - Mreža emancipacije E-net	9	116.251
L - Nezavisna propaganda	18	231.958
L - Osobe	8	635.068
L - Političke stranke	9	282.580
UKUPNO L	86	1.559.569

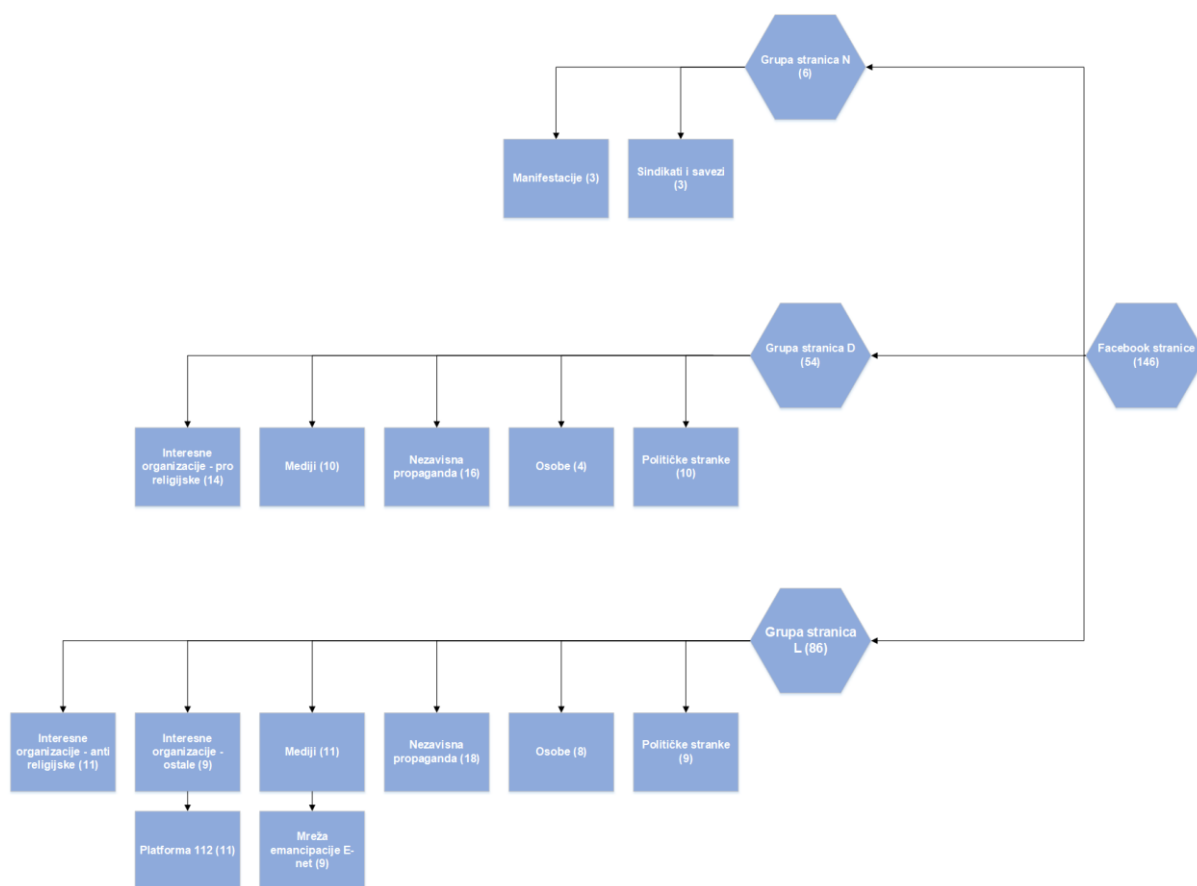
Tablica 4.2.2 - Informacije o broju stranica i broju *fan-ova* unutar pojedine podgrupe Facebook stranica

⁶⁷ Facebook For Developers. *Page - Graphi API Reference*.
<https://developers.facebook.com/docs/graph-api/reference/page/> (23.02.2018.)

Napomena: informacije o broju *fan-ova* su dobivene za vrijeme povlačenja podataka osim za sljedeće stranice koje su svrstane u podgrupu „D - Nezavisna propaganda“: „Kukuriku koalicija nije moja vlada“, „Zbogom Jugoslavijo“ i „Ja sam Hrvat iz Hrvatske, a ne "s ovih prostora"“ i to s datumom 22.02.2018.

U svrhu lakšeg percipiranja procesa svrstavanja stranica u 15 spomenutih podgrupa kreiran je shematski prikaz vidljiv na slici 4.1.1. Detaljniji opisi, odnosno kriteriji prema kojima su Facebook stranice na individualnoj razini svrstavane u pojedine podgrupe navedeni su u sljedećem potpoglavlju.

Tehnički aspekti kreiranja mreže bit će pak objašnjeni u narednom poglavlju.



Slika 4.2.1 - Shematski prikaz grupiranja Facebook stranica s istaknutim ukupnim brojem stranica

4.3. Popis grupiranih stranica

Tablice su definirane tako da prvi stupac predstavlja naziv stranice, drugi stupac adresu stranice koja se nastavlja na osnovnu Facebook domenu (npr. <https://www.facebook.com/zagrebpride>), treći stupac unikatnu identifikacijsku oznaku, a četvrti stupac kratki opis stranice.

4.3.1. Grupa stranica N/Nesvrstana

Manifestacije, sindikati i savezi su izdvojeni u posebnu grupu. Navedene stranice nisu posve politički neutralne, ali su izdvojene jer često predstavljaju svojevrsnu protutežu političkim elitama te ih je stoga zanimljivo promatrati kao bitne faktore u društvenim odnosima. Također, u grupi D i L nije bilo moguće složiti slične ekvivalentne podgrupe pa iz tog razloga navedene stranice bivaju izdvojene.

Stranica	URL: facebook.com/	ID	Opis
Fališ	festival.falis	182381795277610	Udruga koja organizira festival alternative i ljevice
Subversive Festival	subversivefestival	316666381719876	Događaj posvećen ljevici i antifašizmu, organizator udruga „Bijeli Val“
Zagreb Pride	zagrebpride	1790324074529158	Queer-feministička i antifašistička udruga koja organizira istoimeni festival

Tablica 4.3.1 - Grupa stranica "N - Manifestacije"

Stranica	URL: facebook.com/	ID	Opis
Mreža mladih Hrvatske - Croatian Youth Network	CroatianYouthNetwork	133678452137	Savez 66 udruga mladih, promiču interese i prava mladih
Savez samostalnih sindikata Hrvatske	SavezSamostalnihSindikataHrvatske	151914891651139	Najveća sindikalna udruga u Hrvatskoj
Vrijedim više	vrijedimvise	282064278920335	Inicijativa za zapošljavanje mladih. Organizatori: Mreža mladih Hrvatske, Savez samostalnih sindikata Hrvatske i Matica hrvatskih sindikata

Tablica 4.3.2 - Grupa stranica "N - Sindikati i savezi"

4.3.2. Grupa stranica D/Politički desno orijentirana

U Hrvatskoj djeluje veći broj udruga koje propagiraju zabranu pobačaja. U tom smislu njihovo djelovanje je često izrazito medijski popraćeno, a događaji koje organiziraju imaju širok društveni utjecaj. Najpoznatije udruge popisane su u tablici.

Stranica	URL: facebook.com/	ID	Opis
40 dana za život - Hrvatska	40.dana.za.zivot.Hrvatska	1376305442630073	Ekumenska molitvena inicijativa, hrvatski ogranak
Centar za nerođeni život Betlehem-Zagreb	Centar-za-nerođeni-život-Betlehem-Zagreb-194487140590369	194487140590369	Udruga koja se bori protiv pobačaja
CRO-BIOS Hrvatski bračni i obiteljski savez	CRO-BIOS-Hrvatski-bračni-i-obiljski-savez-115287971884695	115287971884695	Udruga promiče zaštitu braka i obitelji
Duhos Osijek	duhos	229680927066080	Neformalna zajednica osječkih studenata, promiču kršćansku vjeru
I ja sam bio embrij	I-ja-sam-bio-embrij-144255262357360	144255262357360	Inicijativa udruge „Viligare“ za prava nerođene djece
Molitvena Obiteljska Mreža	MolitvenaObiteljska Mreza	154071384760705	Inicijativa udruge „Blaženi Alojzije Stepinac“
Nepomireni	nepomireni	175615265910928	Neformalna građanska inicijativa, organizatori akcije „Ne dirajte im djetinjstvo“
Opus Dei Hrvatska	Opus-Dei-Hrvatska-496794460364053	496794460364053	Lokalni ogranak međunarodne kršćanske organizacije
SKAC Palma	SkacPalma	144249492290964	Udruga „Studentski katolički centar“ koja se bavi kršćanskom mišlju
Udruga za promicanje obiteljskih vrijednosti - Blaženi Alojzije Stepinac	udrugabas	289189144435944	Udruga zastupa promicanje obiteljskih vrijednosti
U ime obitelji	UImeObitelji	238516626294245	Udruga koja promiče tradicionalne vrijednosti braka i obitelji
Vigilare	Vigilare	410274919036976	Konzervativna udruga koja promiče dostojanstvo i kulturu života
Zdravstveni odgoj	ZdravstveniOdgoj	351484938280734	Edukacijski portal udruge „Građani odlučuju“
Betlehem - Život biraj	zivotbiraj	117085581760402	Krovna stranica različitih udruga „Betlehem“

Tablica 4.3.3 - Grupa stranica "D - Interesne organizacije - pro religijske"

U pogledu medija namjerno se nije analiziralo velike izdavačke kuće. Oni bliski desnom političkom spektru i konzervativnijem (religijskom) svjetonazoru odabrani su zbog načelne proklamirane nezavisnosti, čestog isticanja neprofitnog karaktera i slične tematske orijentiranosti. Najčešće ne propagiraju opće teme poput većina *news* portala.

Stranica	URL: facebook.com/	ID	Opis
Bitno.net	Bitno.net	186119338137148	Neprofitni kulturno-vjerski portal
braniteljski-portal	braniteljskiportalhr	62039055527	Nezavisni portal posvećen braniteljima
Croative.net	Croativenet	281648028582259	Medijski projekt „Hrvatske udruge Benedikt“
Hrvatsko Nebo	hrvatskonebo	1502063563345985	Portal posvećen Domovinskom ratu
Kamenjar.com	kamenjarinfo	299408570193772	Nezavisni hrvatski portal
Hrvatske Žrtve Komunističkog Genocida	komunistickizlocini.net	1096080243739893	Portal posvećen komunističkim zločinima
Maxportal.hr	maxportal.hr	253498621440547	Medijski portal udruge „Agramer info“
Narod.hr	narod.hr	444477142341814	Medijski portal udruge „U ime Obitelji“
Raskrižje - Hrvatski katolički portal	raskrizje	167797849919536	Nezavisni katolički portal
Hrvatsko Obrambeno Štivo	Striclwann	1700531456834935	Desničarski medijski portal

Tablica 4.3.4 - Grupa stranica "D - Mediji"

U smislu manjih političkih stranaka hrvatske desnice sljedeće egocentrične mreže su grupirane zajedno:

Stranica	URL: facebook.com/	ID	Opis
Autohtona - Hrvatska stranka prava	AutohtonaHSP	995070957294170	Stranka ekstremno desne orijentacije, osnovana 2005.
Autohtona Hrvatska stranka prava	autohtonipravsihr	1658773571027641	Druga stranica gore navedene stranke
Hrvatska čista stranka prava - HČSP	hcsp.hr.zds	546686375529810	Stranka osnovana 1992. nakon izdvajanja članova iz HSP-a
HDSSB	hdssb.hr	233000365301	Regionalna stranka osnovana 2005. odlaskom Branimira Glavaša iz HDZ-a
HRAST - pokret za uspješnu Hrvatsku - službene stranice	HRAST.hr	1481525755446572	Osnovana 2012. nakon raskola sa strankom Hrast, predsjednik Ladislav Ilčić
Hrvatska stranka prava - HSP	hrvatska.stranka.prava.hr	125430330838752	Najstarija pravaška stranka u modernoj Hrvatskoj osnovana 1990.
HSP dr. Ante Starčević	hspas	218305558329097	Pravaška stranka koju je osnovala Ruža Tomašić 2009.
Hrvatska Stranka Prava 1861	IstinskiPravasi	253103731706720	Stranku je osnovao 1995. Dobroslav Paraga, bivši predsjednik HSP-a
Neovisni za Hrvatsku	Neovisni-za-Hrvatsku-130582554107848	130582554107848	Osnovana 2017. od strane B. Esih, Z. Hasanbegovića i Ž. Glasnovića
Projekt Domovina	uio.projektdomovina	121565101531082	Politički projekt udruge „U ime obitelji“

Tablica 4.3.5 - Grupa stranica "D - Političke stranice"

Nezavisna propaganda označava grupu stranica koje u svojem opisu ne odaju pripadnost nikakvoj interesnoj organizaciji, mediju ili tome slično. Tko administrira takve stranice nije poznato no njihova tematika se uglavnom svodi na potporu braniteljima, veličanju Domovinskog rata i borbe protiv snaga lijevog spektra.

Stranica	URL: facebook.com/	ID	Opis
Kukuriku koalicija nije moja vlada	Kukuriku-koalicija-nije-moja-vlada-235837656485324	235837656485324	Stranica posvećena djelovanju protiv SDP-a
Partizani i komunisti su najveća sramota Hrvata	Partizani.i.komunisti.su.najveca.sramota.Hrvata	275038262695840	Sadržaj orijentiran protiv partizana i komunista
Zbogom Jugoslavijo	croatia.zbogom.jugoslavijo	143690782351382	Stranica se bori protiv jugonostalgije
Zahtijevam ostavku ministra Jovanovića	DeleteJovanovic	437137833017585	Aktivnosti su usmjerene protiv bivšeg ministra kulture SDP-a
Potpore Đuri Glogoskom	Duro.GlogoskiOfficial	788295661241364	Stranica potpore Đuri Glogoskom
Građanska Akcija	Građanska-Akcija-1083592488386962	1083592488386962	Sadržaj usmjeren prema snagama političke ljevice
Ja sam Hrvat iz Hrvatske, a ne "s ovih prostora"	HrvatskaHrvatom	197528436950804	Stranica veliča domoljublje i borbu protiv jugonostalgije
HRVATSKE OBRAMBENE SNAGE (HOS)	hrvatskeobrambene snage	74717781648	Ekstremno desno orijentirana stranica
Potpore Zlatku Hasanbegoviću	Potpore.ministrukulture	663990167075896	Potpore bivšem ministru kulture iz kvote HDZ-a
PRIZNAJEM! HRVAT SAM	priznajem.HRVATsam	138368646244241	Domoljubna stranica usmjerena protiv lijevog političkog spektra
Smrt komunizmu	Smrt-komunizmu-637982092996328	637982092996328	Stranica djeluje protiv komunizma
Ujedinjenje Hrvatskih Domoljuba i Branitelja	UjedinjenjeHrvatskih DomoljubalBranitelja	466382513421474	Sadržaj glorificira Domovinski rat
VOLIM HRVATSKU - NE U EU	VOLIM-HRVATSKU-NE-U-EU-128249073871285	128249073871285	Stranica ugašene udruge i stranke „Volim Hrvatsku“, promiče euroskepticizam
ZABORAVLJENI SINOVI DOMOVINSKOG RATA	ZABORAVLJENI-SINOVI-DOMOVINSKOG-RATA-1592210154403374	1592210154403374	Stranica posvećena hrvatskim braniteljima
Za Dom Spremni	ZaDomSpremn1991	750591544970306	Veličanje Domovinskog rata i borba protiv snaga ljevice
ZA HRVATSKU I KRISTA PROTIV KOMUNISTA	ZA-HRVATSKU-I-KRISTA-PROTIV-KOMUNISTA-1423620451088459	ZA-HRVATSKU-I-KRISTA-PROTIV-1423620451088459	Širenje propagande usmjerene kontra komunista

Tablica 4.3.6 - Grupa stranica "D - Nezavisna propaganda"

Kod odabira osoba s desnog političkog spektra također je vođeno računa da iste ne dolaze iz velikih stranka, ali su u grupi razmatrani političari koji više nisu u vodstvu istih takvih stranka (npr. Tomislav Karamarko usprkos malom broju odlaznih veza njegove stranice).

Stranica	URL: facebook.com/	ID	Opis
Branimir Glavaš	BranimirGlavas	74334663835	Hrvatski političar desne orijentacije
Velimir Bujanec	bujica.velimir.bujane c	360777920735548	Novinar, voditelj TV emisije „Bujica“
Ladislav Ilčić	ilcic.ladislav	621823571235813	Predsjednik stranke HRAST
Tomislav Karamarko	tomislav.karamarko	333460020045365	Bivši predsjednik HDZ-a

Tablica 4.3.7 - Grupa stranica "D - Osobe"

4.3.3. Grupa stranica L/Politički lijevo orijentirana

Kao prva podskupina interesnih organizacija grupirane su one egocentrične mreže koje se odnose na organizacije koje zastupaju pravo na pobačaj i često su u koliziji s načelima koje propagira Crkva.

Stranica	URL: facebook.com/	ID	Opis
Nisam Vjernik	aktivni.ateisti	195874490453475	Inicijativa građana koja promovira sekularnost
Center for Civil Courage	CenterForCivilCourage	330223803666704	Udruga „Centar za građansku hrabrost“, podržavaju sekularnost i pravo na pobačaj
DAVID - Udruga građana za zaštitu ljudskih prava	davidudruga	168294809904795	Udruga koja se zalaže za prava agnostika, ateista i neformalnih vjernika
Obrani PRAVO NA IZBOR	obranipravo	842421182557279	Inicijativa „Platforme za reproduktivna prava“, zastupaju pravo na pobačaj
Protagora	protagora.hr	166963543331012	Udruga za zaštitu prava ireligioznih osoba i promicanje ireligioznog poimanja svijeta
Pokret za sekularnu Hrvatsku	sekularna	476698289034475	Inicijativa „Glasa razuma - pokreta za sekularnu Hrvatsku“, protiv definicije braka kao zajednice muža i žene. U projektu su sudjelovale i udruge „Protagora“ i „Centar za građansku hrabrost“
LiberOs	udruga.liberos	659281480781346	Udruga za promiče borbu za ljudska prava, protiv vatikanskih ugovora
Udruga PaRiter	udrugapariter	1480250818931293	Zalažu se za pravo na pobačaj, toleranciju, prava manjina i rodnu ravnopravnost
Vjeronauk.org	vjeronaukvanizskola	322879567761122	Projekt inicijative „Nisam vjernik“ koja za cilj ima izbacivanje vjeronauka iz škola
Ženska mreža Hrvatske	ZenskaMrezaHrvatske	549285728554915	Zastupaju prava žena na feminističkim principima, zalažu se na pravo za pobačaj
Znaj znanje	ZnajZnanje	553983691399525	Projekt udruge „PaRiter“, zalažu se za pravo na pobačaj

Tablica 4.3.8 - Grupa stranica "L - Interesne organizacije - anti religijske"

U grupu ostalih interesnih organizacija svrstane su one koje ističu vrijednosti poput antifašizma, borbe protiv krupnog kapitala i općenito čine protutežu desnom političkom spektru. Neke organizacije su povezane s održavanjem prosvjeda za kurikularnu reformu. Napomena: u skupini D nije bilo moguće kreirati ekvivalentnu grupu koja bi činila protutežu stranicama iz nastavka.

Stranica	URL: facebook.com/	ID	Opis
Udruga Antifašista grada Korčule	AntifasistiKorcule	607214785969650	Promiču vrijednosti antifašizma
Antifašistička liga Republike Hrvatske	Antifašistička-liga-Republike-Hrvatske-660279774042403	660279774042403	Promicanje antifašizma, osnivači su „Documenta“, „Srpsko narodno vijeće“ i drugi
Centar za radničke studije	CentarZaRadnickeStudije	126990537450216	Posvećeni promociji marksizma
Crvena akcija	crvena.akcija.antifa	247846961897474	Antifašistička, antikapitalistička i antiimperijalistička neformalna grupa
Hrvatska može bolje	HrvatskaMozeBolje	862481813896683	Inicijativa podržava kurikularnu reformu, koordinirana od strane udruga lijevog spektra
MAMA Zagreb	MamaZagreb	159041947576283	Net.kulturni kub MaMa promiče inovativne kulturne prakse i kritične društvene pozicije
Savica ZA Park	savicazapark	459971580755108	Inicijativa „Čuvamo naš park“ koja je protiv eksploatacije istoimenog parka u Zagrebu
Srpsko narodno vijeće	SrpskoNarodnoVijeće	1449669341953227	Nacionalna koordinacija vijeća srpske nacionalne manjine
Društvo "Josip Broz Tito" Rijeka	Tito.Rijeka	240196579361405	Organizacija koja štiti sjećanje na Titov lik i djelo

Tablica 4.3.9 - Grupa stranica "L - Interesne organizacije - ostale"

Kao posebna podskupina podskupine izdvojena je Platforma 112 i stranice svih organizacije koje čine istu, a da su u trenutku prikupljanja podataka bile aktivne na Facebooku i zadovoljile tražene kriterije. Na službenoj stranici ove platforme stoji sljedeći opis: „Platforma 112 okuplja organizacije civilnog društva koje se niz godina bave zaštitom ljudskih prava, demokratizacijom, izgradnjom mira, suzbijanjem korupcije i zaštitom javnih resursa“.⁶⁸ Razlog iz kojeg je Platforma 112 svrstana kao podskupina interesnih organizacija lijevog spektra leži u činjenici da se njihove aktivnosti često poklapaju i tematski vežu upravo s ostalim interesnim organizacijama koje su opisane u prethodnoj tablici. Platforma 112 je također podržala prosvjede za kurikularnu reformu.

Napomena: tablica u nastavku sadrži upravo one organizacije koje su u vrijeme povlačenja podataka činile jezgru Platforme 112 te da su njihove Facebook stranice zadovoljavale ranije definirane preduvjete za povlačenje podataka. Krajem siječnja, odnosno početkom veljače 2018. godine došlo je do određenih organizacijskih promjena tako da su na službenim stranicama neke organizacije izbrisane (npr. „Portal H-Alter“ ili „Transparency International Hrvatska“), a neke dodane poput primjerice „Zagreb Pride“ ili „Protagora“.

(Tablica je vidljiva na sljedećoj stranici)

⁶⁸ Platforma 112. *Tko smo*. <http://www.kucaljudskihprava.hr/platforma-112/tko-smo/> (27.12.2017.)

Stranica	URL: facebook.com/	ID	Opis
BaBe - Budi aktivna. Budi emancipiran.	BaBeZagreb	306717366194537	Organizacije se zalaže za ženska prava i rodnu ravnopravnost
CESI - Centar za edukaciju, savjetovanje i istraživanje	CentarCESI	125377507527732	Feministička organizacija koja ističe žensku i rodnu ravnopravnost
Centar za mirovne studije	CentarzaMirovneStudije	163908197037158	Organizacija koja promiče nenasilje i ljudska prava
GONG	gong.hr	135611546456409	Potiču građane na aktivnije sudjelovanje u političkim procesima
Kuća ljudskih prava Zagreb / Human Rights House Zagreb	kucaljudskihprava	299688546509	Mreža šest organizacija civilnog društva iz Zagreba
Platforma 112 - za Hrvatsku vladavine prava	Platforma112ZaHrvatskuVladavinePrava	195875390538482	Glavna Facebook stranica Platforme 112
H-Alter	PortalH.Alter	78216830676	Portal izvještava o akcijama i inicijativama u civilnom društvu
Pravo na grad	PravoNaGrad	518185914888142	Inicijativa usmjerena protiv prekomjerne ekonomske eksploatacije prostora
Centar za LGBT ravnopravnost	ravnopravnost.hr	202417023133480	Promiču prava homo/biseksualnih i transrodnih osoba
Transparency international Hrvatska	Transparency-international-Hrvatska-134631933227579	134631933227579	Organizacija posvećena suzbijanju korupcije
Zelena akcija / FoE Croatia	Zelenaakcija	176565220704	Udruga osnovana 1990. koja promiče zaštitu okoliša

Tablica 4.3.10 - Grupa stranica "L - Interesne organizacije - ostale - Platforma 112 - za Hrvatsku vladavine prava"

U pogledu medija također postoje dvije podskupine. Glavnu podgrupu također kao i u skupini D čine manji mediji koji se najčešće proklamiraju kao nezavisni i neprofitni te propagiraju stavove koji su često oprečni spomenutim medijima desnog spektra.

Stranica	URL: facebook.com/	ID	Opis
Info zona	infozona.hr	181371261990133	Istoimena udruga i medijski portal za mlade
Kulturpunkt.hr	Kulturpunkt	89410579392	Projekt udruge „Kurziv“ koji prati nezavisnu kulturu i građanske inicijative
Antifašistički Vjesnik	antifavjesnik	1544316125820434	Portal promiče narodnooslobodilačku borbu i socijalističko nasljeđe
KontraPortal	kontraportal	643596085745301	Antikapitalistički, antifašistički, antiimperijalistički i antiglobalistički žurnal
Le Monde diplomatique hrvatsko izdanje	LeMondeDiplomatiqueHrvatska	327122447394412	Hrvatsko izdanje međunarodnih novina, izdavač je „KopMedija - zadruga za medije“
Muf	mufcomhr	533764276718776	Portal istoimene udruge za feminističku kritiku popularne kulture
Portal Booksa.hr	portalbooksa	1413548335618137	Portal o književnosti udruge „Kulturtreger“
Libela.org	PortalLibela	212908915406099	Stranice pružaju informacije o rodu, spolu i demokraciji, projekt udruge „CESI“
Radnička prava	radnickaprava.org	811441908882554	Portal udruge „BRID“ s temama radničkih prava i borbe,
Televizija Student	TelevizijaStudent	296094830476950	Jedina studentska televizija na području RH
VIZKULTURA	vizkultura	604306196252097	Portal o vizualnim umjetnostima i kulturi istoimene udruge

Tablica 4.3.11 - Grupa stranica "L - Mediji"

Mreža emancipacije E-net jest otvorena platforma 11 organizacija i inicijativa od kojih je 10 medija trećeg sektora. Osnovana je u ožujku 2015. s ciljem povećanja društvenog utjecaja takvih medija radi veće vidljivosti tema od javnog interesa.⁶⁹ Mediji trećeg sektora se definiraju kao mediji koji djeluju unutar organizacija civilnog društva.⁷⁰ Mreža je također podržala prosvjede za kurikulum, a propagira sadržaj sličnog tipa stranicama iz tablice posvećene medijima. Valja napomenuti da neki udruge članice nisu imale adekvatne Facebook stranice za analizu.

Stranica	URL: facebook.com/	ID	Opis
Radio Student	RadioStudentZG	184527598227943	Prva studentska radio postaja u Hrvatskoj, registrirani kao udruga
Mreža emancipacije E-net	emancipacija	1052672971431534	Službene stranice platforme
Forum tjedni magazin	forumtm	184063491666149	Medijski portal udruge „Dom kulture Zagreb“
Lupiga.com	lupiga	166048427573	Medijski portal „Udruge za promicanje medijske kulture, umjetnosti i tolerancije „Lupiga - svijet kroz obične oči““
Mreža Antifašistkinja Zagreba	Mreža-Antifašistkinja-Zagreba-787731051321372	787731051321372	Udruga koja se bavi aktivizmom, izdaju i časopis „Nepokoreni grad“
PortalCroL	PortalCroL	206961822737111	LGBT portal udruge za medijski aktivizam „CroL“
Radio808	Radio808	167270729972990	Nezavisni internet radio „Udruge za promicanje medijskog pluralizma 808“
Slobodni Filozofski	slobodni.filozofski	393274794177860	Udruga koja stoji iza istoimenog portala, povezani s prosvjedima na Filozofskom fakultetu
Zarez	Zarez-113772295314716	113772295314716	Dvotjednik za kulturna i društvena zbivanja, izdavač je istoimena udruga

Tablica 4.3.12 - Grupa stranica "L - Mediji - Mreža emancipacije E-net"

⁶⁹ Facebook Fan Page. *Mreža emancipacije E-net*.
<https://www.facebook.com/emancipacija/about/> (28.12.2017.)

⁷⁰ ŠAGO, V. *Medijska strategija Europske unije prema medijima Trećeg sektora (diplomski rad)*. Zagreb: Fakultet političkih znanosti, 2017., str. 64.

Stranice koje potpadaju pod nezavisnu propagandu ljevice nisu administrirane od strane poznatih osoba ili organizacija. Tematika se također svodi na propagiranje antifašizma, borbu protiv kapitala, političke desnice, Crkve i tome slično.

Stranica	URL: facebook.com/	ID	Opis
Antifa Šibenik	antifa.sibenik	293142127547904	Stranica promovira antifašističke ideje i vrijednosti
Mladi antifašisti grada Splita	antifa.st	158458214170370	Identično kao i Antifa Šibenik
Antifa Zagreb	antifa.zagreb	142881419077664	Identično kao i Antifa Šibenik
Antifašistički front	Antifafront	249136088615345	Identično kao i Antifa Šibenik
Ateisti i agnostici Hrvatske	ateistihrvatske	1473999932906687	Promoviraju ateizam i kritiziraju Crkvu te desne političke opcije
Gradjanska Akcija	Gradjanska.Akcija.Hrvatske	486588188141742	Kritika desnih političkih opcija
Tko je ZA to da HDZ vrati sve novce koje je ukrao u zadnjih 20+ godina?	HDZvratiukradeno	618200031551588	Stranica kritizira HDZ i desne političke snage
HRVATSKA PROTIV FAŠIZMA	HRVATSKA-PROTIV-FAŠIZMA-306638266165732	306638266165732	Stranica promovira sadržaj usmjeren protiv fašizma
JA glasam protiv	JAGlasamprotiv	1450236091783430	Nepoznati autori, protiv definicije braka kao zajednice muža i žene na referendumu 2013
Krvava povijest Crkve	KrvavaPovijestCrkve	417328088346457	Stranica posvećena kritiziranju Crkve
Lobotomizator	Lobotomizator-638324332891521	638324332891521	Objave primarno kritiziraju HDZ
Otpor Kapitalistima	Otpor-Kapitalistima-1082876741738895	1082876741738895	Stranica je posvećena borbi protiv kapitalizma
Pinokolinda	Pinokolinda-336942173174468	336942173174468	Većina sadržaja je usmjerena protiv Predsjednice RH
Pro-choice Hrvatska	prochoicehrvatska	296973983827407	Zastupaju pravo na pobačaj
Racionalist	Racionalist	173253526071330	Stranica kritizira desne političke stranke
Smijenimo Bandića	smijenimobandica	305186153002952	Objave prikazuju gradonačelnika Zagreba u lošem svjetlu
Tihogovornik	Tihogovornik-243469312521735	243469312521735	Sadržaj promovira antifašizam i borbu protiv desnih političkih opcija
Ustaše su najveća sramota Hrvata	Ustaše-su-najveća-sramota-Hrvata-363155633818603	363155633818603	Stranica usmjerena protiv Crkve i desnih političkih opcija

Tablica 4.3.13 - Grupa stranica "L - Nezavisna propaganda"

Ekvivalent podgrupi iz skupne D. Sadrži osobe iz manjih političkih stranka kao i osobe bliske lijevom političkom miljeu. Na listu je uvršten i bivši Predsjednik RH budući da je istupio iz SDP-a.

Stranica	URL: facebook.com/	ID	Opis
Boris Dežulović	dezulovic	208080499209485	Novinar i pisac, jedan od suosnivača Feral Tribunea
Ivo Josipović	ivojosipovicprh	230377845124	Bivši Predsjednik RH, bivši član SDP-a, trenutni član stranke Naprijed Hrvatska
Josip Kregar	Josip-Kregar-437225893072435	437225893072435	Profesor i političar, član stranke Naprijed Hrvatska
Kruno Lokotar	Kruno-Lokotar-1672891022967950	1672891022967950	Književnik i pisac
Milorad Pupovac	Milorad-Pupovac-284379738398650	284379738398650	Predsjednik Srpskog Narodnog Vijeća i političke stranke SDSS
Miljenko Jergović	Miljenko-Jergović-876045789176916	876045789176916	Pisac i novinar
Ivan Pernar	pernari	1382789368713509	Političar i saborski zastupnik Živog Zida
Zoran Šprajc	zoran.sprajc	107558500835	Novinar i voditelj RTL televizije

Tablica 4.3.14 - Grupa stranica "L - Osobe"

Stranke ljevice grupirane su u sljedeću grupu i predstavljaju manje političke stranke, baš kao i slučaju desnih ekvivalenata.

Stranica	URL: facebook.com/	ID	Opis
Komunistička partija Hrvatske	Komunistička-partija-Hrvatske-777443532277502	777443532277502	Stranka ekstremne ljevice
Mladi Socijalisti	Mladi-Socijalisti-179409195436468	179409195436468	Autonomna organizacija u okviru Socijalističke Radničke Partije Hrvatske
Naprijed Hrvatska - Progresivni savez	naprijedhrvatskanhp	382986581909465	Stranka koju je osnovao bivši Predsjednik RH Ivo Josipović
ORaH	orah.hr	215268971970847	Stranka lijevog centra, osnivač bivša ministrica Mirela Holy
Radnička Fronta	RadnickaFronta	770459529655215	Stranka ekstremnog lijevog političkog spektra
Socijalistička radnička partija Hrvatske	srphrvatske	398029840305021	Ekstremno lijeva politička stranka
ZA GRAD	StrankaZaGrad	503074389754825	Primarno lokalna stranka koja djeluje u gradu Zagrebu
Zagreb je NAŠ	ZagrebJeNAS	389347084776786	Politička platforma za lokalne izbore u Zagrebu usmjerena protiv Milana Bandića
Živi zid	zivizidd	291638950941144	Aktivističko - politička organizacija, veliki kritičari aktualnog financijskog sustava

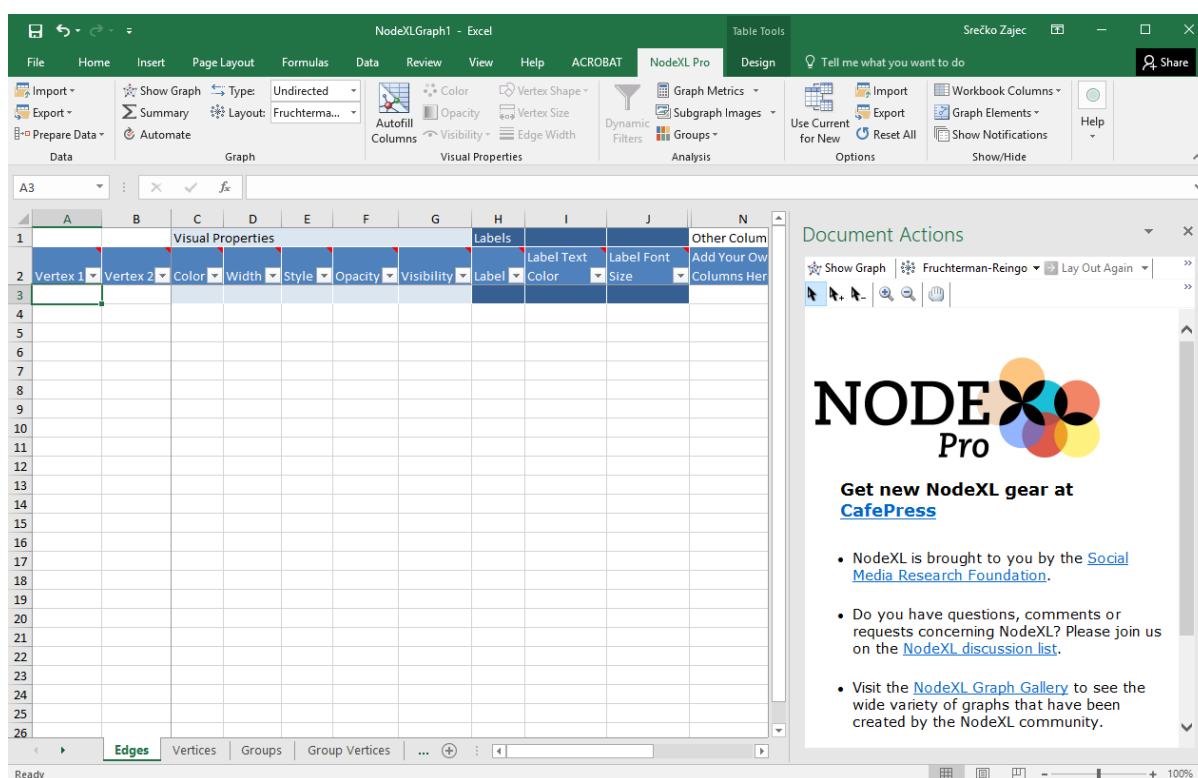
Tablica 4.3.15 - Grupa stranica "L - Političke stranke"

5. Povlačenje i priprema podataka

5.1. Povlačenje podataka

Analizi i vizualizaciji podataka prethodio je postupak prikupljanja istih koji se proveo putem NodeXL dodatka (eng. *plug-in*) za Excel.⁷¹ Radilo se sa komercijalnom studentskom inačicom koja sadrži sve funkcionalnosti originalno predviđene od strane proizvođača.

Osnovni izgled sučelja za dodatak NodeXL vidljiv je na slici 5.1.1. Pri tome valja istaknuti da sve funkcionalnosti spomenutog dodatka unutar postojeće Excel instalacije možemo naći unutar istoimenog *taba* u glavnom izborniku. Opcije koje NodeXL pruža grupirane su ovisno o namjeni, primjerice povlačenje podataka, zatim operacije koje se odnose na izračune različitih mrežnih metrika, izrada vizualizacija i tome slično.



Slika 5.1.1 - NodeXL - izgled osnovnog sučelja

⁷¹ Social Media Research Foundation. *NodeXL - Your Social Network Analysis Tool for Social Media*. <https://www.smrfoundation.org/nodexl/> (07.02.2018.)

Kako bi se postigla što veća konzistentnost podaci su ciljano prikupljeni u kratkom vremenskom roku. To se odnosilo na periode navedene u sljedećoj tablici:

Facebook stranice	Razdoblje povlačenja podataka
Grupa stranica N	27.09. - 05.10.2017.
Grupa stranica L	27.09. - 05.10.2017.
Ispravak za stranicu „Radio 808“	18.10.2017.
Grupa stranica D	20.10. - 25.10.2017.
Ispravak za stranicu „Autohtona Hrvatska stranka prava“	30.10.2017.

Tablica 5.1.1 - Informacije o vremenskim razdobljima povlačenja podataka s interneta

Valja naglasiti da NodeXL ima unaprijed zadani set opcija koji se odnose na mogućnost samog povlačenja podataka. U konkretnom slučaju koji se tiče Facebook stranica odabrane postavke prikazane su na slici 5.1.2.

Import from Facebook Fan Page Network

The NodeXL Facebook fan page network will download the connections between contributors in the specified fan page. You can search and select a fan page by typing in the text box. After you login and authorize the application, you can click download.

[Click here to logout from Facebook.](#)

Fan Page
Name/ID:

Attributes

Attribute	Include
Name	<input checked="" type="checkbox"/>
First Name	<input checked="" type="checkbox"/>
Middle Name	<input checked="" type="checkbox"/>
Last Name	<input checked="" type="checkbox"/>
Hometown	<input checked="" type="checkbox"/>
Location	<input checked="" type="checkbox"/>
Birthday	<input checked="" type="checkbox"/>
Age Range	<input checked="" type="checkbox"/>
Picture	<input checked="" type="checkbox"/>
Email	<input checked="" type="checkbox"/>
Timezone	<input checked="" type="checkbox"/>
Gender	<input checked="" type="checkbox"/>
Religion	<input checked="" type="checkbox"/>
Relationship	<input type="checkbox"/>
Political Views	<input type="checkbox"/>
Favorite Athletes	<input type="checkbox"/>
Favorite Teams	<input type="checkbox"/>
Inspirational People	<input type="checkbox"/>

☒ Network

☒ Vertices

☐ User ☐ Post ☒ Page

☐ Relationship

☒ Reaction ☒ Share ☒ Comment

☒ Create a directed edge between

☐ reactor/commenter/sharer and post author

☐ two consecutive commenters

☐ reactor/commenter/sharer and comment author

☐ post/comment author and user tagged

☒ pages which like each other

☐ Create an undirected edge between

☐ users who reacted to/commented in/shared the same post

☐ posts that have the same reactor/commenter/sharer

☐ posts (self-loops)

Options

☒ Download from post 1 to post 100

☐ Download posts between 14.12.2017. and 14.12.2017.

☐ Limit the number of pages to collect to 50

☒ Include also posts not made by the page owner

☒ Get status updates (slow)

Login Download Cancel

Slika 5.1.2 - NodeXL - Odabrane postavke za povlačenje podataka

Glavne karakteristike procesa svode se na unos imena odabrane stranice te odabiranje opcija o stvaranju usmjerenih veza koje vode od odabrane stranice prema onima koje ishodišna stranica slijedi (egocentrična mreža). Također, za sve navedene *node*-ove povučen je i niz javno dostupnih podataka (atributa) koji se vežu uz adresu stranice, naziv, broj sljedbenika, opis, itd. Svaka stranica spremljena je datoteka u Excel formatu .xlsx. Valja naglasiti da opisani proces u pogledu dostupnih opcija podrazumijeva kreiranje dvostupanjske mreže što znači da se povlačenje odnosi na sve stranice koje slijedi odabrana stranica (prvi stupanj) te sve stranice koje slijede stranice koje slijedi ishodišna stranica (drugi stupanj). Ako želimo obuhvatiti sve takve stranice potrebno je ostaviti opciju „*Limit the number of pages to collect to...*“ praznom.⁷²


Glavni nedostaci ovako opisanog procesa dotiču se vremenskog limita koji je definiram preko Facebook API-a (povlačenje podataka za jednu stranicu traje ponekad i preko desetak minuta - zavisno o broju veza) te nemogućnosti odstupanja od unaprijed zadanih opcija čemu se može doskočiti uporabom drugih alata navedenim pod poglavljem preporuke.

Napomena: sve originalne datoteke i podaci su u slučaju potrebe dostupni za pregled i verifikaciju.

⁷² Smith, M. *Osobna korespondencija putem e-mail adrese marc@smrfoundation.org.* (26.09.2017.)

5.2. Priprema podataka

Proces pripreme podataka odnosi se na tehničku izvedbu koja za finalni cilj ima pripremiti prikupljene podatke na način kako smo to zamislili u konceptualnom i strukturnom smislu. Tek tada ja moguće vršiti različite analize i posljedične vizualizacije. U ovom konkretnom slučaju proces je sadržavao transformiranje dvostupanjske u jednostupanjsku egocentričnu mrežu, snimanje podataka, ispravljanje eventualnih grešaka uočenih kod *importa*, njihovo ispravljanje te ponovno *importiranje* i grupiranje u softver za analizu i vizualizaciju.



Slika 5.2.1 - NodeXL - postupak brisanja mreže drugog stupnja

Postupak transformacije dvostupanjske u jednostupanjsku mrežu obavljen je jednostavnim operacijama u NodeXL-u. U sklopu prikaza svih veza isključen je prikaz veza za stranicu koju obrađujemo nakon čega su obrisane veze stranica koja obrađivana stranica slijedi (slika 5.3). Tako pročišćen dokument spremljen je u

.graphml datoteku pogodnu za import u analitički softver Gephi. Oblik datoteke .graphml⁷³ bazira se na .xml formatu⁷⁴ i omogućuje fleksibilno spremanje različitih podataka o nekoj mreži (npr. niz atributa za pojedinu stranicu - *node*).

Kao alternativa se javlja snimanje mreže u .net formatu pogodnom za analizu u softveru Pajek no navedeni format ne omogućava zapisivanje atributa.⁷⁵ Takav tip datoteke moguće je dobiti snimanjem podataka iz NodeXL-a, ali i iz Gephia.

Prilikom *importa* podataka u pojedinim slučajevima je došlo do pogrešaka u učitavanju. To se najčešće odnosilo na sljedeće:

- mreža je bila zapisana kao neusmjerena pa ju je trebalo transformirati u usmjerenu;
- pojedine numeričke varijable od potencijalnog interesa (npr. broj sljedbenika neke stranice) bile su definirane kao *string* umjesto *integer*;
- neki opisi stranica bili su zapisani u stranim jezicima koji nisu podržani (npr. pojedine dijakritike) pa je iste trebalo obrisati;
- poneki *node-ovi* iz drugostupanjske mreže ostali su zapisani u datoteci pa ih je trebalo ručno obrisati.

Za eventualne potrebe ispravljanja nastalih grešaka korišten je tekstualni editor Notepad++ koji omogućuje jednostavno uređivanje .xml te ostalih programskih datoteka. U nastavku su priloženi primjeri u kojima je kroz jednostavne postupke provedena transformacija neusmjerene u usmjerenu mrežu (slika 5.4) ili pak promjena tipa varijabli (slika 5.5).

Valja napomenuti da su nastale greške u zapisima vjerojatna posljedica sitnijih *bugova* u samom NodeXL-u.

⁷³ Gephi. *GraphML Format*.

<https://gephi.org/users/supported-graph-formats/graphml-format/> (19.12.2017.)

⁷⁴ W3Schools. *XML Tutorial*.

<https://www.w3schools.com/xml/> (15.12.2017.)

⁷⁵ Gephi. *Pajek NET Format*.


<https://gephi.org/users/supported-graph-formats/pajek-net-format/> (19.12.2017.)


```
121 <key id="E-Opacity" for="edge" attr.name="Opacity" attr.type="string" />
122 <key id="E-Visibility" for="edge" attr.name="Visibility" attr.type="string" />
123 <key id="E-Label" for="edge" attr.name="Label" attr.type="string" />
124 <key id="E-Label Text Color" for="edge" attr.name="Label Text Color" attr.type="string" />
125 <key id="E-Label Font Size" for="edge" attr.name="Label Font Size" attr.type="string" />
126 <key id="E-Reciproccated?" for="edge" attr.name="Reciproccated?" attr.type="string" />
127 <key id="E-ID" for="edge" attr.name="ID" attr.type="string" />
128 <key id="E-Dynamic Filter" for="edge" attr.name="Dynamic Filter" attr.type="string" />
129 <key id="E-Add Your Own Columns Here" for="edge" attr.name="Add Your Own Columns Here" attr.type="string" />
130 <key id="E-Relationship" for="edge" attr.name="Relationship" attr.type="string" />
131 <key id="E-Type" for="edge" attr.name="Type" attr.type="string" />
132 <key id="E-Edge Weight" for="edge" attr.name="Edge Weight" attr.type="string" />
133 <graph edgedefault="undirected">
134 <node id="infozona.hr">
135 <data key="V-Image File">https://scontent.xx.fbcdn.net/v/t1.0-1/p50x50/217844_214440752016517_169531/
136 <data key="V-Custom Menu Item Text">Open Facebook for This Page</data>
137 <data key="V-Custom Menu Item Action">https://www.facebook.com/181371261990133</data>
138 <data key="V-Picture">https://scontent.xx.fbcdn.net/v/t1.0-1/p50x50/217844_214440752016517_16953530/
139 <data key="V-About">Više od informacije!</data>
140 <data key="V-Category">Non-Governmental Organization (NGO)</data>
141 <data key="V-Checkins">461</data>
142 <data key="V-Cover">https://scontent.xx.fbcdn.net/v/t31.0-8/s720x720/21544007_1283586608435254_1259/
143 </node>
144 <node id="NajProfesori.Split">
145 <data key="V-Image File">https://scontent.xx.fbcdn.net/v/t1.0-1/c0.64.440.440/s50x50/215403_1810184/
146 <data key="V-Custom Menu Item Text">Open Facebook for This Page</data>
147 <data key="V-Custom Menu Item Action">https://www.facebook.com/137925206258106</data>
148 <data key="V-Picture">https://scontent.xx.fbcdn.net/v/t1.0-1/c0.64.440.440/s50x50/215403_1810184952/
149 <data key="V-About">Nominiraj svog NajProfesora: http://www.sveuciliste-u-sjeni.org/najprofesori/no
150 <data key="V-Category">Education</data>
151 </node>
152 </graph>
```

Slika 5.2.2 - Notepad++ - ispravak greške - transformacija iz neusmjerene u usmjerenu mrežu

```
46 <key id="V-Category" for="node" attr.name="Category" attr.type="string" />
47 <key id="V-Category List" for="node" attr.name="Category List" attr.type="string" />
48 <key id="V-Checkins" for="node" attr.name="Checkins" attr.type="string" />
49 <key id="V-Company Overview" for="node" attr.name="Company Overview" attr.type="string" />
50 <key id="V-Contact Address" for="node" attr.name="Contact Address" attr.type="string" />
51 <key id="V-Country Page Likes" for="node" attr.name="Country Page Likes" attr.type="string" />
52 <key id="V-Cover" for="node" attr.name="Cover" attr.type="string" />
53 <key id="V-Culinary Team" for="node" attr.name="Culinary Team" attr.type="string" />
54 <key id="V-Current Location" for="node" attr.name="Current Location" attr.type="string" />
55 <key id="V-Description" for="node" attr.name="Description" attr.type="string" />
56 <key id="V-Directed By" for="node" attr.name="Directed By" attr.type="string" />
57 <key id="V-Display Subtext" for="node" attr.name="Display Subtext" attr.type="string" />
58 <key id="V-Response Time" for="node" attr.name="Response Time" attr.type="string" />
59 <key id="V-E-mails" for="node" attr.name="E-mails" attr.type="string" />
60 <key id="V-Engagement" for="node" attr.name="Engagement" attr.type="string" />
61 <key id="V-Fan Count" for="node" attr.name="Fan Count" attr.type="integer" />
62 <key id="V-Featured Video" for="node" attr.name="Featured Video" attr.type="string" />
63 <key id="V-Features" for="node" attr.name="Features" attr.type="string" />
64 <key id="V-Food Styles" for="node" attr.name="Food Styles" attr.type="string" />
65 <key id="V-Founded" for="node" attr.name="Founded" attr.type="string" />
66 <key id="V-General Info" for="node" attr.name="General Info" attr.type="string" />
67 <key id="V-General Manager" for="node" attr.name="General Manager" attr.type="string" />
68 <key id="V-Genre" for="node" attr.name="Genre" attr.type="string" />
69 <key id="V-Has Added App" for="node" attr.name="Has Added App" attr.type="string" />
70 <key id="V-Hometown" for="node" attr.name="Hometown" attr.type="string" />
71 <key id="V-Hours" for="node" attr.name="Hours" attr.type="string" />
72 <key id="V-Influences" for="node" attr.name="Influences" attr.type="string" />
73 <key id="V-Is Always Open" for="node" attr.name="Is Always Open" attr.type="string" />
74 <key id="V-Is Community Page" for="node" attr.name="Is Community Page" attr.type="string" />
75 <key id="V-Is Eligible For Branded Content" for="node" attr.name="Is Eligible For Branded Content" attr.type="string" />
76 <key id="V-Is Permanently Closed" for="node" attr.name="Is Permanently Closed" attr.type="string" />
77 <key id="V-Is Verified" for="node" attr.name="Is Verified" attr.type="string" />
78 <key id="V-Link" for="node" attr.name="Link" attr.type="string" />
79 <key id="V-Location" for="node" attr.name="Location" attr.type="string" />
80 <key id="V-Members" for="node" attr.name="Members" attr.type="string" />
81 <key id="V-Mission" for="node" attr.name="Mission" attr.type="string" />
82 <key id="V-Mpg" for="node" attr.name="Mpg" attr.type="string" />
83 <key id="V-Name" for="node" attr.name="Name" attr.type="string" />
84 <key id="V-Network" for="node" attr.name="Network" attr.type="string" />
```

Slika 5.2.3 - Notepad++ - ispravak greške - promjena numeričke varijable iz *string* u *integer*



Slika 5.2.4 - Gephi - postupak *importa* mreže u .graphml formatu

Jedan od niza razloga zašto je .graphml izrazito praktičan format za pohranu mrežnih podataka jest i činjenica da Gephi omogućuje kombiniranje većeg broja takvih datoteka (odnosno mreža) u jednu veću mrežu, a što je u ovoj analizi obilato korišteno. To znači da je svaka egocentrična mreža za pojedinu stranicu mogli lako biti grupirana s drugim stranicama ako se prilikom *importa* koristila opcija *append* (slika 5.6). Izvorni .gephi format tako nešto ne omogućuje tako da je upravo korištenjem .graphml datoteka bilo moguće postići različite vrste grupiranja prema konceptu koji je unaprijed bio definiran. Slično važi i za .gexf format⁷⁶ koji se također bazira na .xml standardu, a također je korišten za snimanje projekata nastalih u vizualizacijskom softveru, posebice u kasnijim fazama analize koje su slijedile nakon inicijalnog uvoza podataka. Valja napomenuti da .graphml i .gexf formati kod korištenja opcije *append* omogućuju automatsko presnimavanje bilo kakvih identičnih *node-ova* ili veza tako da je dupliciranje bilo izbjegnuto.


Jednom grupirane egocentrične mreže bile su spremne za analizu i vizualizaciju.

⁷⁶ Gephi. *GEXF File Format*. <https://gephi.org/gexf/format/> (06.01.2018.)

6. Analiza i vizualizacija podataka

6.1. Opis najvažnijih funkcionalnosti softvera te pregled osnovnog procesa analize i vizualizacije

Dok je povlačenje i priprema podataka rađena pretežito u Windows 10 okruženju, u pogledu analize i vizualizacije podjednako je korišten i operativni sustav macOS High Sierra v10.13 uz identične funkcionalnosti korištenih programa. Navedeno se odnosi prvenstveno na već spomenuti Gephi (v0.9.2).



Slika 6.1.1 - Gephi - izgled osnovnog sučelja

U smislu korištenja samog softvera temeljni preduvjet za vizualizaciju bilo je provođena kalkulacija vezanih uz metrike od interesa. Navedeno se u sklopu sučelja (slika 6.1.1) nalazi s desne strane pod tabom *Statistics*. Za izračun svih metrika korištene su osnovne postavke programa zbog konzistentnosti i usporedivosti rezultata.

Što se pak tiče same manipulacije vizualima, tab *Appearance* (lijeva strana sučelja) omogućuje navedeno. Finale vizualizacije temeljile su se na dvije glavne karakteristike. Tako valja istaknuti da veličinu pojedinog entiteta predstavlja vrijednost izračunate metrike centraliteta za taj isti entitet (veći krug (entitet) = veća vrijednost). Drugo, u procesu se koristio koncept izrade mreža prema kojem se boje koriste za označavanje entiteta i njihovih odlaznih veza kako bi se naglasila njihova pripadnost određenoj grupi. To često podrazumijeva označavanje različitih komponenti (klastera) mreže različitim bojama, međutim u ovom konkretnom slučaju boje su korištene kako bi se naglasila pripadnost entiteta i njihovih veza pojedinim podgrupama stranica koje su definirane ranije u ovom radu. Pri tome valja istaknuti da je korištenjem *Data Laboratory-a* (vrh sučelja) ručno trebalo unijeti set vrijednosti za naknadno dodani atribut koji je označavao upravo pripadnost pojedinog čvora određenoj podgrupi. Valja napomenuti da su sivom bojom označeni entiteti koji se nalaze u mreži, ali podaci o njihovim egocentričnim mrežama nisu povučeni, odnosno nisu bili predmetom inicijalne analize.

Neizostavan dio vizualizacija mreže predstavljaju tzv. *energy layouts* koji su bazirani na različitim algoritmima te pomažu u završnom stadiju vizualizacije.⁷⁷ To rade na način da mrežu vizualno poslože tako da se čvorovi koji su međusobno više povezani privlače, a oni manje povezani se udaljuju. Za potrebe vizualizacija priloženih u nastavku korišteni su algoritmi ForceAtlas2 i Yifan Hu.⁷⁸

U nastavku je analizirana povezanost najzanimljivijih grupa zbog njihovog neposrednog društvenog, političkog i ekonomskog utjecaja. Tako su se postavila pitanja poput:

- kako su međusobno povezane organizacije s lijeve, odnosno s desne strane političkog spektra, koji *node-ovi* su najvažniji u smislu metrika centraliteta;
- kako izgleda mrežni prikaz svih entiteta s lijeve strane političkog spektra, a kako s desne;
- kakva je međusobna povezanost entiteta koji bi u načelu trebali biti nezavisni i nepovezani (npr. političke stranke, mediji i udruge).

⁷⁷ Gephi. *Gephi Tutorial Quick Start*. <https://gephi.org/users/quick-start/> (07.01.2018.)

⁷⁸ Gephi. *Gephi Tutorial Layouts*. <https://gephi.org/users/tutorial-layouts/> (07.01.2018.)

Sve rečeno je bila glavna nit vodilja u pogledu izrade razumljivih mrežnih vizualizacija. Ranija spomenuta važnost pojedinih *node-ova* temeljem izračunatih metrika reflektira se upravo kroz njihovu moć propagiranja informacija u pretpostavljenom modelu. Na to se direktno naslanja teorija o takozvanim nerazmjernim mrežama⁷⁹ koje karakterizira distribucija zakona potencije, tj. postojanje većeg broja *node-ova* s malo veza, odnosno manjeg broja s puno veza. Takve mreže su svojstvene za sustave koje je stvorio čovjek, baš poput interneta i društvenih mreža. U kontekstu ovog istraživanja posebice je zanimljiva činjenica da su opisane mreže izrazito osjetljive na napade prema važnim *node-ovima* te njihovim brisanjem distribucija informacija postaje teža. U prijevodu, ovdje do značaja dolazi ono što je već nekoliko puta istaknuto - znanje o bitnim entitetima (stranicama) može nam povećati učinkovitost plasiranja informacija od našeg interesa, odnosno omogućiti neutraliziranje protivnika ili u najmanju ruku otežati njegovo djelovanje.

Sljedeće poglavlje stoga predstava svojevrsni završni dio ovog istraživačkog procesa u kojem su konačno predstavljeni rezultati onog do čega se dolazilo kroz sva ova poglavlja.

U nastavku su provedene dvije zasebne analize povezanosti Facebook stranica i to za kombinaciju stranica iz grupe D te kombinaciju stranica iz grupe L i N kako bi se ustanovilo da li postoji kakva povezanost između stranica navedenih dviju skupina. Posljedične vizualizacije su finalni produkt ovih analiza.

⁷⁹ KOPAL, R., KORKUT, D., KRNJAŠIĆ, S. Analiza (socijalnih) mreža: praktična primjena. Zagreb: IN2data d.o.o. / Visoko učilište Algebra, 2016., str. 73.

6.2. Vizualizacija mreže Facebook stranica grupe D

Prvi dio analize odnosi se na tehničke karakteristike mreže koja se sastoji od 54 egocentrične mreže, odnosno 54 Facebook stranica ranije podijeljenih u pet različitih podgrupa. Dijametar mreže iznosi 13 (najkraći put između dva najudaljenija *node-a*), a prosječna geodetska udaljenost između dva *node-a* iznosi 5,11. U mreži se ukupno nalazi 830 entiteta povezanih s 1258 veza. Distribuciju ukupnog broja veza za sve *node-ove* karakterizira zakon potencije što ide u prilog tome da se radi o nerazmjernoj mreži.

Nakon što je provedena analiza komponenti ustanovljeno je da mrežu čini njih 17 pri čemu stupanj grupiranja iznosi 0,664. Navedeno govori o umjerenoj grupiranosti i pretežitoj otpornosti mreže spram nasumičnih napada što znači da je potrebno utvrditi najbitnije *node-ove* kroz postupak računanja metrika centraliteta.

Najveća komponenta pokriva 20.84% mreže i u nastavku će biti također zasebno analizirana. U navedenih 20.84% ulazi 173 entiteta i 259 veza.

S obzirom na same karakteristike mreže i potrebi da se vizualizacije moraju prikazati na papiru A4 formata odabran je Yifan Hu *energy layout* koji je pokazao najbolje rezultate za ovakvu formu prikaza.

Kao što je već spomenuto, vizualizacije koriste boje za označavanje pripadnosti entiteta (i njihovih odlaznih veza) pojedinim (interesnim) podgrupama stranica, a veličina pojedinog entiteta označava relativnu veličinu zadane metrike centraliteta spram ostalih entiteta.

Generirana oznaka	Udio komponente u ukupnoj mreži
1	20,84%
8	14,82%
11	11,33%
2	6,99%
5	6,63%
12	5,42%
4	5,06%
6	4,94%
14	4,58%
3	4,46%
0	4,34%
10	3,86%
7	3,61%
9	1,81%
13	0,6%
15	0,48%
16	0,24%

Tablica 6.2.1 - Popis komponenti i njihov udio u ukupnoj mreži - mreža stranica grupe D


Boja podgrupe	Naziv podgrupe
	Nije analizirano
	D - Interesne organizacije - pro religijske
	D - Mediji
	D - Nezavisna propaganda
	D - Osobe
	D - Političke stranke

Tablica 6.2.2 - Legenda boja koja označava podgrupe Facebook stranica - mreža stranica grupe D

U nastavku su priložene tablice koje se odnose na izračunate tri metrike centraliteta, redom *Betweenness*, *Closeness* i *PageRank*. U top deset stranica koje povezuju različite dijelove mreže (vrijednost za *Betweenness*) primarno ulaze tri različite podgrupe koje su podjednako podijelile navedenih prvih deset pozicija. To su mediji („Narod.hr“, „Braniteljski portal“, „Bitno.net“), zatim pro religijske stranice poput „U ime obitelji“, „40 dana za život“ i „Zdravstveni odgoj“, a listu zaključuju tri stranice iz skupine nezavisne propagande - „Ujedinjene hrvatskih domoljuba i branitelja“, „Partizani i komunisti su najveća sramota Hrvata“ te „Ja sam Hrvat iz Hrvatske, a ne „s ovih prostora““. Zanimljivo, na desnoj strani vizualizacije je vidljiva veća povezanost pro religijskih (cijan boja) i medijskih (narančasta boja) stranica.

Stranica	<i>Betweenness</i>
Narod.hr	15433,54
braniteljski-portal	12503,47
Ujedinjenje Hrvatskih Domoljuba i Branitelja	12067,06
Partizani i komunisti su najveća sramota Hrvata	10104,72
HRAST - pokret za uspješnu Hrvatsku - službene stranice	6181,50
U ime obitelji	5918,30
40 dana za život - Hrvatska	5120,25
Ja sam Hrvat iz Hrvatske, a ne "s ovih prostora"	4971,42
Bitno.net	4826,20
Zdravstveni odgoj	4676,17

Tablica 6.2.3 - Deset najvećih vrijednosti za metriku centraliteta *Betweenness* - mreža stranica grupe D



Slika 6.2.1 - Vizualizacija mreže temeljem različitih podgrupa Facebook stranica (boje) i metrike centraliteta *Betweenness* (veličina entiteta) - mreža stranica grupe D

Entiteti koji imaju veliki potencijal za širenje vijesti kroz mrežu nabrojani su u tablici koja ima prikazane vrijednosti za metriku *Closeness*. Budući da algoritam koristi normaliziranu vrijednost za izračun, mogući rezultati uvijek se nalaze u rasponu između 0 i 1.^{80, 81} Čak petnaest stranica dijeli vrijednost 1,0 pa su zbog njihove brojnosti stranice s manjim vrijednostima izostavljene s popisa. U tom smislu navedeni entiteti imaju najkraći mogući put do drugih entiteta, tj. pogodni su za brzo širenje informacija. Za ovu mjeru centraliteta zabilježena je apsolutna dominacija političkih stranaka (zelena boja) i osoba (plava boja). Pri tome se također izdvajaju i tri stranice iz pro religijske podgrupe cijan boje („Centar za nerođeni život Betlehem“, „CRO-BIOS“ i „Opus Dei Hrvatska“) te tri iz nezavisne propagande roze boje („Za Dom Spremni“, „ZABORAVLJENI SINOVI DOMOVINSKOG RATA“ i „VOLIM HRVATSKU - NE U EU“). Valja istaknuti da stranice „Autohtona - Hrvatska stranka prava“ i „Neovisni za Hrvatsku“ pripadaju izdvojenim komponentama ove mreže. Stranka Autohtona - Hrvatska stranka prava je u vrijeme povlačenja podataka imala dvije stranice od kojih je jedna naknadno ugašena i/ili pripojena drugoj.

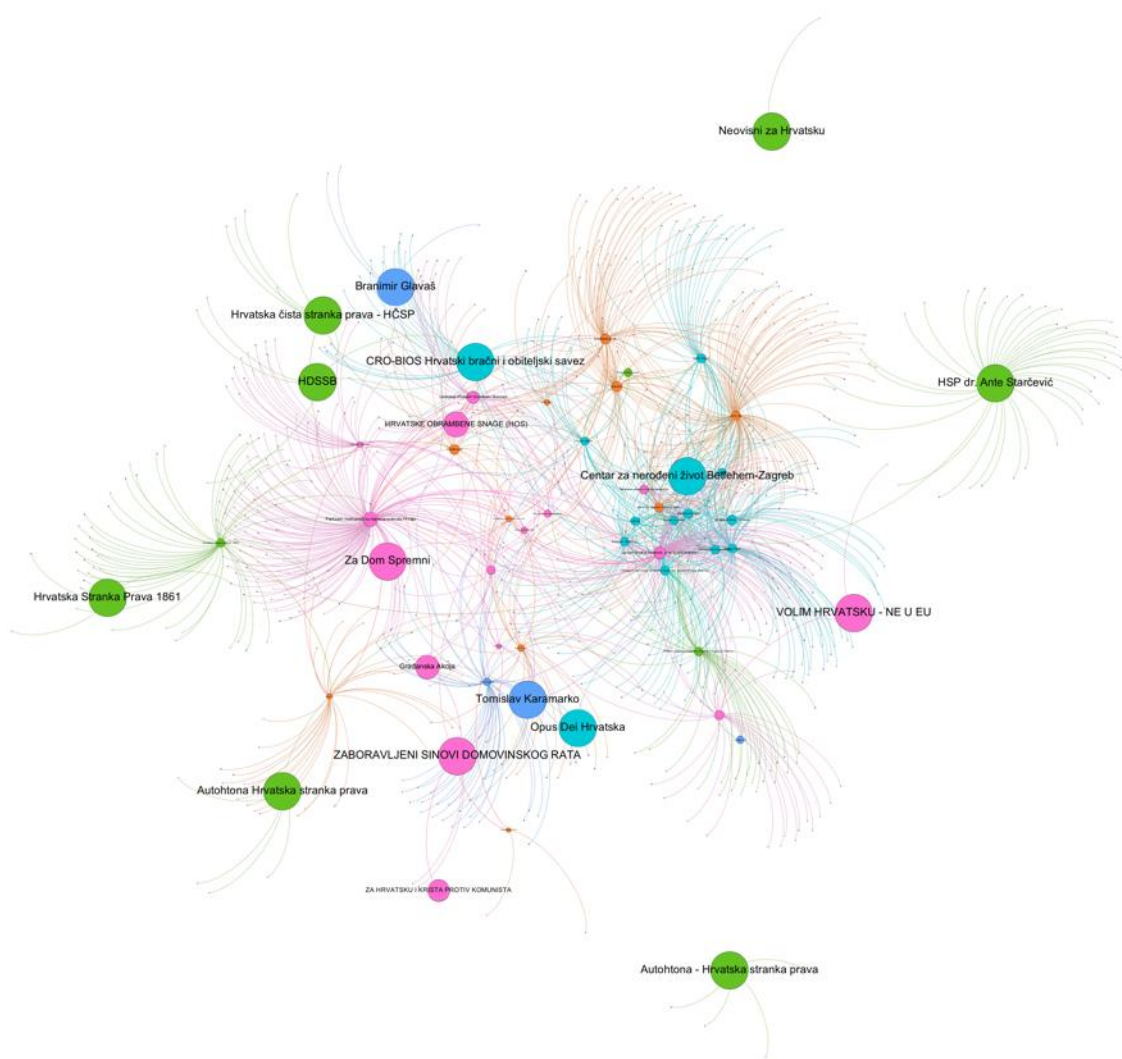
Stranica	<i>Closeness</i>
Centar za nerođeni život Betlehem-Zagreb	1,0
CRO-BIOS Hrvatski bračni i obiteljski savez	1,0
Opus Dei Hrvatska	1,0
Tomislav Karamarko	1,0
ZABORAVLJENI SINOVI DOMOVINSKOG RATA	1,0
Za Dom Spremni	1,0
Hrvatska čista stranka prava - HČSP	1,0
VOLIM HRVATSKU - NE U EU	1,0
Branimir Glavaš	1,0
Autohtona - Hrvatska stranka prava	1,0
Autohtona Hrvatska stranka prava	1,0
HDSSB	1,0
HSP dr. Ante Starčević	1,0
Hrvatska Stranka Prava 1861	1,0
Neovisni za Hrvatsku	1,0

Tablica 6.2.4 - Petnaest najvećih vrijednosti za metriku centraliteta *Closeness* - mreža stranica grupe D

⁸⁰ Github. *Closeness Centrality*.

<https://github.com/gephi/gephi/wiki/Closeness-Centrality> (13.02.2018.)

⁸¹ BRANDES, U. *A Faster Algorithm for Betweenness Centrality*. Konstanz : KOPS - Institutional Repository of the University of Konstanz, 2001., str. 3.

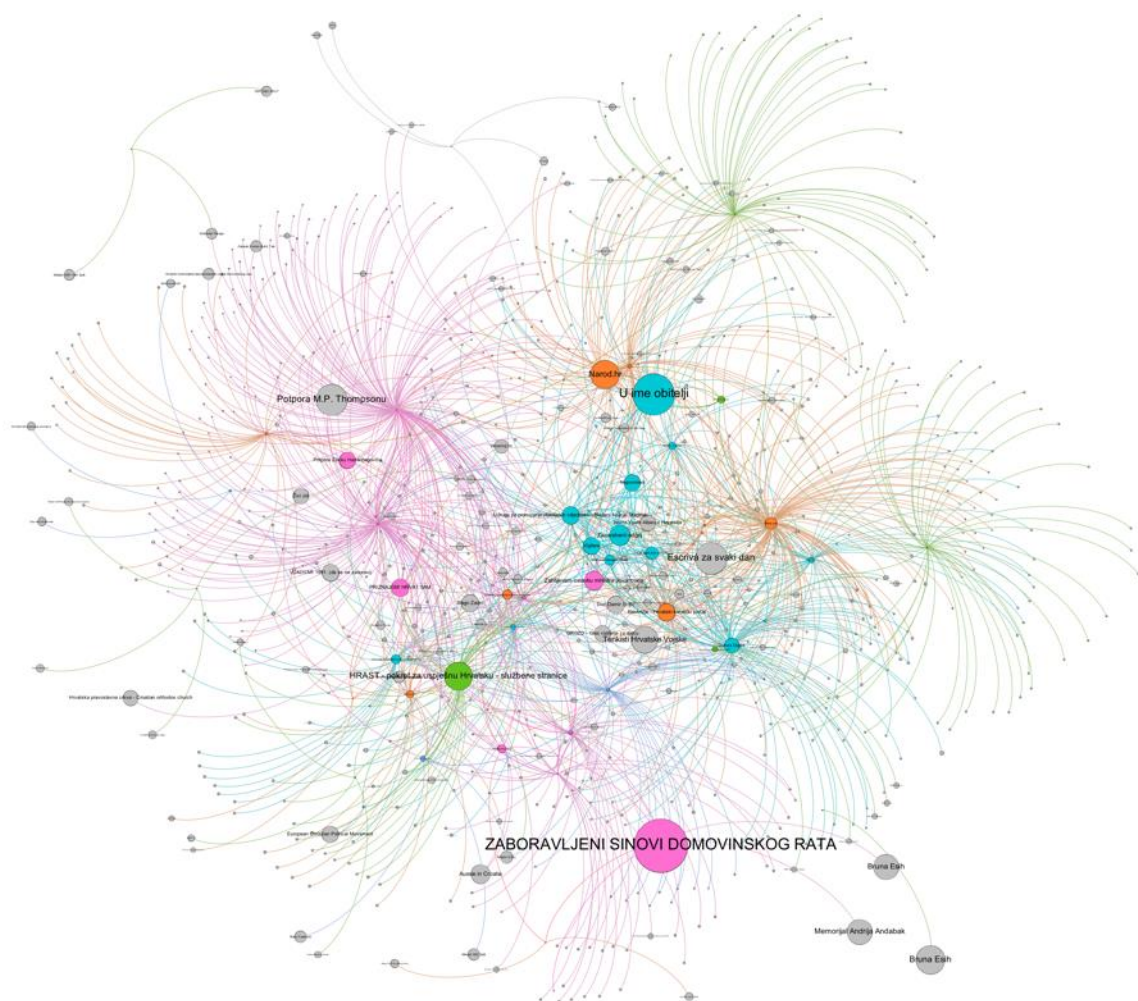


Slika 6.2.2 - Vizualizacija mreže temeljem različitih podgrupa Facebook stranica (boje) i metrike centraliteta *Closeness* (veličina entiteta) - mreža stranica grupe D

U pogledu *PageRanka*, odnosno stranica koje preuzimaju dio utjecaja od drugih stranica s kojima su povezane prisutna je tematska diversifikacija stranica pa tako najveće vrijednosti zauzimaju stranice iz podgrupa koje se odnose na nezavisnu propagandu („ZABORAVLJENI SINOVI DOMOVINSKOG RATA“ - roza boja), pro religijske organizacije („U ime obitelji“ - cijan boja), medije („Narod.hr“ - narančasta boja), političke stranke („HRAST“ - zelena boja). Neke od navedenih stranica (egocentričnih mreža) nisu uopće ubačene u analizu, ali su se pojavile kao entiteti od prikrivenog značaja sive boje („Escrivá za svaki dan“, „Potpora M.P. Thompsonu“, itd.). Valja napomenuti da je političarka Bruna Esih u vrijeme povlačenja podataka imala dvije stranice od kojih je jedna naknadno ugašena i/ili pripojena drugoj. Ni za jednu od navedene dvije stranice nisu direktno povlačeni podaci o egocentričnoj mreži.

Stranica	<i>PageRank</i>
ZABORAVLJENI SINOVI DOMOVINSKOG RATA	0,00295
U ime obitelji	0,00253
Escrivá za svaki dan	0,00220
Potpore M.P. Thompsonu	0,00217
Bruna Esih	0,00209
Narod.hr	0,00208
HRAST - pokret za uspješnu Hrvatsku - službene stranice	0,00207
Tenkisti Hrvatske Vojske	0,00202
Bruna Esih	0,00197
Memorijal Andrija Andabak	0,00197

Tablica 6.2.5 - Deset najvećih vrijednosti za metriku centraliteta *PageRank* - mreža stranica grupe D



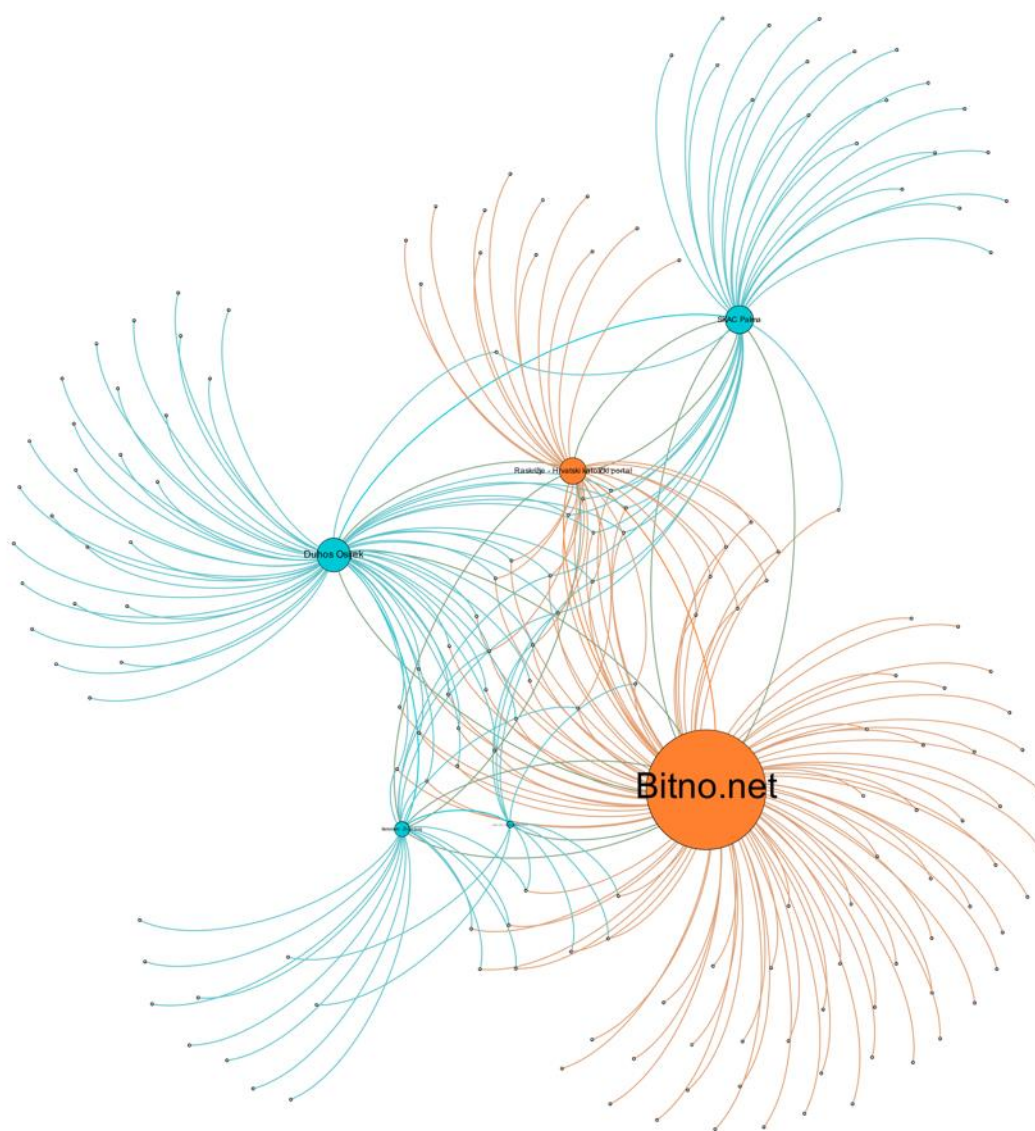
Slika 6.2.3 - Vizualizacija mreže temeljem različitih podgrupa Facebook stranica (boje) i metrike centraliteta *PageRank* (veličina entiteta) - mreža stranica grupe D

Provedena analiza izdvojene najveće komponente za *Betweenness* potvrđuje snagu medija „Bitno.net“ (narančasta boja). Na ovoj razini jedino se spomenuta stranica izdvaja kao ona koja se pojavljuje i među top deset *node-ova* za spomenutu mjeru u pogledu analize kompletne mreže. Zanimljivo je da većina entiteta s najvećom vrijednošću u pogledu najsnažnije komponente proizlazi iz podskupine stranica koja se odnose na pro religijske organizacije (cijan boja). Vizualizacija zorno prikazuje kako najvećom komponentom dominiraju upravo spomenute dvije grupacije - pro religijska i medijska što nedvojbeno ukazuje na njihovu izraženu povezanost koja je već ranije spomenuta.

Na priloženoj tablici samo šest stranica poprima vrijednosti metrike veću od nule.

Stranica	<i>Betweenness</i>
Bitno.net	399,50
Duhos Osijek	104,83
SKAC Palma	85,17
Raskrižje - Hrvatski katolički portal	80,67
Betlehem - Život biraj	41,33
Centar za nerođeni život Betlehem-Zagreb	12,5

Tablica 6.2.6 - Šest najvećih vrijednosti za metriku centraliteta *Betweenness* u najvećoj komponenti - mreža stranica grupe D

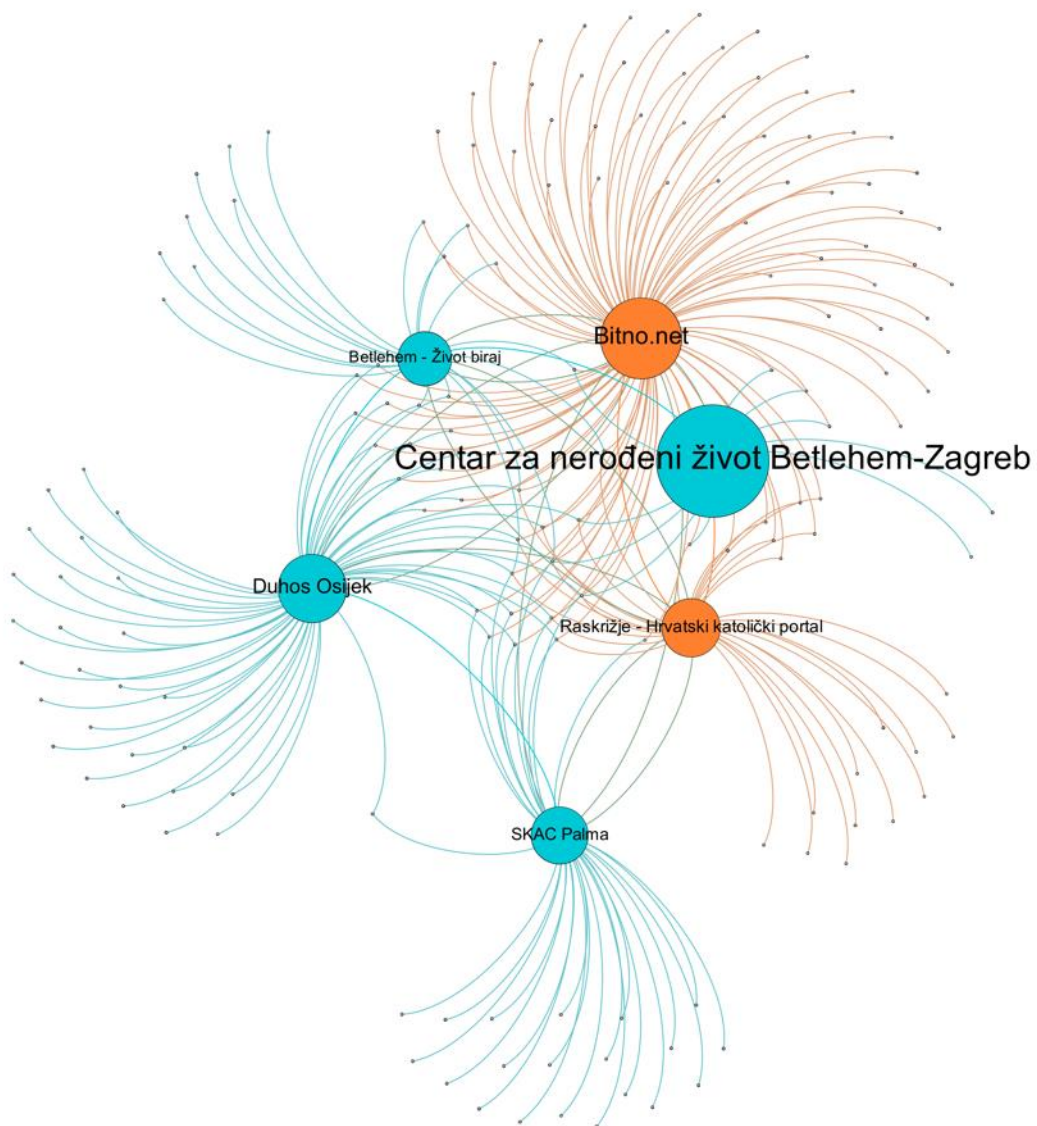


Slika 6.2.4 - Vizualizacija najveće komponente temeljem različitih podgrupa Facebook stranica (boje) i metrike centraliteta *Betweenness* (veličina entiteta) - mreža stranica grupe D

Kao i za *Betweenness* na razini najistaknutije komponente, u slučaju mjere *Closeness* također vrijede slične karakteristike. Stranica „Centar za nerođeni život Betlehem“ jedina ima mjeru 1,0 te se pojavljuje među najjačim *node-ovima* za spomenutu metriku na razini kompletne mreže. Portal „Bitno.net“ niti u pogledu *Closenessa* ne zaostaje te ovom mjerom dodatno potvrđuje svoju važnost.

Stranica	<i>Closeness</i>
Centar za nerođeni život Betlehem-Zagreb	1,0
Bitno.net	0,71
Duhos Osijek	0,60
Raskrižje - Hrvatski katolički portal	0,51
SKAC Palma	0,49
Betlehem - Život biraj	0,47

Tablica 6.2.7 - Šest najvećih vrijednosti za metriku centraliteta *Closeness* u najvećoj komponenti - mreža stranica grupe D



Slika 6.2.5 - Vizualizacija najveće komponente temeljem različitih podgrupa Facebook stranica (boje) i metrike centraliteta *Closeness* (veličina entiteta) - mreža stranica grupe D

PageRank za najveću komponentu također naglašava važnost religijskih organizacija, međutim kao što je već bio slučaj prije i ovdje se pojavljuju neke stranice čije egocentrične mreže nisu uopće povlačene (a također potpadaju primarno pod religijsku tematiku). Tako primjerice stranice „Isus“, „Prostor Duha“, „Isusovci“ ili pak „Mali, sitni, ali Bogu bitni!“ preuzimaju dio utjecaja zbog entiteta koji ih slijede. Valja još jednom napomenuti da sve stranice koje nisu bile predmetom inicijalne analize označene sivom bojom.

Stranica	<i>PageRank</i>
Isus	0,00678
Prostor Duha	0,00655
Isusovci	0,00640
Mali, sitni, ali Bogu bitni! (Protiv pobačaja!)	0,00638
MARIJINA LEGIJA ŽUPE KAMEN	0,00631
Pastoral mladih	0,00628
Bitno.net	0,00623
Hrvatsko katoličko društvo medicinskih sestara i tehničara	0,00616
KATOLIK	0,00616
Bog moj i sve moje	0,00616
Ured HBK za mlade	0,00612

Tablica 6.2.8 - Deset najvećih vrijednosti za metriku centraliteta *PageRank* u najvećoj komponenti - mreža stranica grupe D

6.3. Vizualizacija mreže Facebook stranica grupe L i grupe N

U pogledu općih karakteristika ova mreža se sastoji od 92 (86+6) egocentrične mreže koje su bile podijeljene u 10 (8+2) podgrupa. Usprkos mnogo većem broju *node-ova* (4645) i veza (7863) dijametar ove mreže je gotovo upola manji od ranije analizirane te iznosi 7, a isto važi i za prosječnu geodetsku udaljenost koja je u ovom slučaju jednaka 2,99. Ova mreža u smislu broja veza za uključene *node-ove* također ima karakterističnu distribuciju zakona potencije.

Što se tiče stupnja grupiranja on je neznatno manji od mreže stranica grupe D - 0,619, a broj komponenti je 15. Kao i u prethodnom slučaju radi se o umjerenoj grupiranosti i mreži koja je relativno otporna na nasumične napade pa je utvrđivanje ključnih *node-ova* neizbježno.

Analiza komponenti nije provedena samo za jednu najveću, već za tri najveće budući da iste međusobno ne odstupaju previše u pogledu veličine, ali i iz razloga da se istraživačkoj analizi pristupi na drugačiji način u odnosu na prethodni slučaj. Tako su izuzete tri komponente koje redom pokrivaju 14.94%, 12.36% i 10.94% mreže. U tih 38.24% mreže ulazi 1776 *node-ova* i 2840 veza.

Boje ponovno predstavljaju pripadnost entiteta i njihovih odlaznih veza određenim interesnim grupacijama. I u ovom slučaju veličina *node-a* zavisi od veličine pojedine metrike centraliteta. Odabrani *energy layout* za vizualizacije je ForceAtlas2 jer je usporednim testiranjem s ranije korištenim *layout-om* Yifan Hu pokazao mnogo bolje rezultate. Naime, zbog karakteristika same mreže (poglavito distribucije najvećih komponenti), ista vizualno izgleda mnogo intuitivnije upravo korištenjem ForceAtlas2 algoritma.

Generirana oznaka	Udio komponente u ukupnoj mreži
12	14,94%
2	12,36%
9	10,94%
7	9,6%
1	9,36%
3	8,57%
4	7,79%
8	5,77%
0	5,62%
11	3,9%
10	2,73%
5	2,48%
6	2,39%
14	1,83%
13	1,72%

Tablica 6.3.1 - Popis komponenti i njihov udio u ukupnoj mreži - mreža stranica grupe L i N

Boja podgrupe	Naziv podgrupe
	Nije analizirano
	N - Manifestacije
	N - Sindikati i savezi
	L - Interesne organizacije - anti religijske
	L - Interesne organizacije - ostale
	L - Interesne organizacije - ostale - Platforma 112
	L - Mediji
	L - Mediji - Mreža emancipacije E-net
	L - Nezavisna propaganda
	L - Osobe
	L - Političke stranke

Tablica 6.3.2 - Legenda boja koja označava podgrupe Facebook stranica - mreža stranica grupe L i N


Kao i u prethodnom poglavlju i u ovom slučaju su izdvojeni rezultati izračuna za glavne metrike centraliteta. Vezano uz mjeru *Betweenness* koja govori o tome koji entiteti kontroliraju komunikaciju između pojedinih dijelova mreže zanimljivo je vidjeti dominaciju - medija - i to još izraženiju nego kod skupine stranica grupe D. Od desetak najvećih vrijednosti čak pet mjesta zauzimaju mediji (roza boja) od kojih neki funkcioniraju unutar takozvane Mreže emancipacije E-net (cijan boja). Tri pozicije zauzima i Platforma 112 označena crvenom bojom („Centar za mirovne studije“, „GONG“, „Zelena akcija“), a zanimljivo je zamijetiti manifestaciju „Zagreb Pride“ na visokom trećem mjestu. Neosporno je da protok informacija između dijelova mreže nadziru stranice koje se ističu kao „nezavisni“ promatrači društvenih i političkih zbivanja (npr. „GONG“), ali da tu istu moć imaju i „nezavisni“ mediji.

Budući da je mreža višestruko veća od one u prethodnom poglavlju, vizualizacija na ovoj razini (slika 6.3.2) ne prikazuje dovoljno jasno umreženost pojedinih interesnih grupacija stoga će u drugoj polovici potpoglavlja ponovno biti potrebno napraviti analizu izdvojenih komponenti.

Napomena: vizualizacije koje se odnose na kompletnu mrežu priložene su u vertikalnoj orijentaciji zbog veće preglednosti.

Stranica	<i>Betweenness</i>
Kulturpunkt.hr	61146,33
H-Alter	54852,93
Zagreb Pride	53009,82
Radio808	46668,92
Centar za mirovne studije	38915,58
Radio Student	37493,44
Libela.org	29146,61
Udruga Antifašista grada Korčule	28601,86
GONG	24480,57
Zelena akcija / FoE Croatia	20934,05

Tablica 6.3.3 - Deset najvećih vrijednosti za metriku centraliteta *Betweenness* - mreža stranica grupe
L i N




Slika 6.3.1 - Vizualizacija mreže temeljem različitih podgrupa Facebook stranica (boje) i metrike centraliteta *Betweenness* (veličina entiteta) - mreža stranica grupe L i N

Sposobnost brzog dosezanja svih dijelova mreže manifestira se kroz metriku *Closeness* pa tako bilježimo čak četiri stranice iz podgrupe koja se odnosi na nezavisnu propagandu (svijetlo zelena boja), dvije anti religijske udruge označene smeđom bojom („Udruga David“, „Ženska mreža Hrvatske“) te po troje jakih individua - Zorana Šprajca, Borisa Dežulovića i Miljenka Jergovića (maslinasto zelena boja). 12 entiteta bilježi vrijednost metrike 1,0 pa su zbog njihove brojnosti kao i u ranijem slučaju izostavljene stranice s manjom vrijednošću. Političke stranke nemaju toliki utjecaj kao u prethodnom slučaju kad je analizirana grupa D.

Stranica	<i>Closeness</i>
DAVID - Udruga građana za zaštitu ljudskih prava	1,0
JA glasam protiv	1,0
Ženska mreža Hrvatske	1,0
Zoran Šprajc	1,0
Slobodni Filozofski	1,0
Boris Dežulović	1,0
Smijenimo Bandića	1,0
Antifašistički front	1,0
HRVATSKA PROTIV FAŠIZMA	1,0
Tko je ZA to da HDZ vrati sve novce koje je ukrao u zadnjih 20+ godina?	1,0
Miljenko Jergović	1,0
Komunistička partija Hrvatske	1,0

Tablica 6.3.4 - Dvanaest najvećih vrijednosti za metriku centraliteta *Closeness* - mreža stranica grupe L i N




Slika 6.3.2 - Vizualizacija mreže temeljem različitih podgrupa Facebook stranica (boje) i metrike centraliteta *Closeness* (veličina entiteta) - mreža stranica grupe L i N

Ako razmatramo *PageRank* možemo zamijetiti nekoliko tipova stranica označenih različitim bojama, baš kao i u slučaju stranica grupe D. Istaknute su individue iz političkog života (Josip Kregar, Ivo Josipović) koji dijele značajan utjecaj iako imaju izrazito malen broj odlaznih veza (maslinasto zelena boja). Isto važi i za njihovu političku platformu „Naprijed Hrvatska“ (ljubičasta boja). Nabrojane su i interesne organizacije poput „MAMA Zagreb“ (žuta) te savez „Mreža mladih Hrvatske“ (tamno plava), ali i pojedini mediji (njih troje na začelju liste). Zanimljivost leži u činjenici da među top 10 ulazi i građanska skupina „U ime svake obitelji“ čija egocentrična mreža uopće nije predmetom analize, baš kao i primjerice N1 Televizija. Što se tiče službenih registriranih organizacija koje kao svoju primarnu agendu ističu borbu za prava homoseksualnih osoba (npr. spomenuta „U ime svake obitelji“) iste uopće nisu uzete u razmatranje kako bi analiza ostala bez predrasuda zbog izrazito osjetljivog karaktera ove društvene teme (pri čemu je bitna i nemogućnost formiranja slične tematske podgrupe stranica u skupini D koje bi činile protutežu istima). Ipak, postaje jasno da su i stranice takvog usmjerenja potencijalno izrazito moćne u propagiranju informacija. Pri tome se valja nadovezati na ranije spomenutu manifestaciju „Zagreb Pride“ koja je primarno gledana kroz prizmu činjenice da se radi o značajnom i utjecajnom javnom događaju, neovisno o agendi. Isto važi i za „PortalCroL“ koji je obuhvaćen analizom čisto iz razloga jer pripada Mreži emancipacije E-net, „Centar za LGBT ravnopravnost“ (dio Platforme 112), kao i stranica „JA glasam protiv“ koja je svrstana u neovisnu propagandu jer joj nije identificiran autor.

Stranica	PageRank
Josip Kregar	0,00072
Naprijed Hrvatska - Progresivni savez	0,00057
MAMA Zagreb	0,00047
Mreža mladih Hrvatske - Croatian Youth Network	0,00043
Ivo Josipović	0,00043
Naprijed Hrvatska Progresivni Savez, PGŽ	0,00042
U ime svake obitelji	0,00042
N1 Televizija	0,00040
H-Alter	0,00038
Libela.org	0,00037

Tablica 6.3.5 - Deset najvećih vrijednosti za metriku centraliteta *PageRank* - mreža stranica grupe L i N




Slika 6.3.3 - Vizualizacija mreže temeljem različitih podgrupa Facebook stranica (boje) i metrike centraliteta *PageRank* (veličina entiteta) - mreža stranica grupe L i N

Analiza tri najistaknutije komponente dodatno je potvrdila snagu *node-ova* koji su ranije spomenuti kao bitni na razini cjelokupne mreže. Tako se za mjeru *Betweenness* ponovno pojavljuju stranice sljedećih entiteta (najčešće udruga): „Centar za mirovne studije“ i „GONG“ iz Platforme 112 obilježeni crvenom bojom te „Kulturpunkt.hr“ (medij - roza boja) i „Udruga Antifašista grada Korčule“ (žuta boja). Njihov značaj je tako u smislu apsolutnog iznosa metrike daleko najveći.

Vizualizacija na ovoj razini jasno prikazuje dominantnu mrežnu povezanost nekoliko grupa: primarno „Platforme 112“ (crvena boja), medija (roza boja) i nezavisne propagande (svijetlo zelena boja). U nešto manjoj mjeri prisutne su i druge grupe, ali navedene tri dominiraju svojom brojnošću, odnosno povezanošću.

Stranica	<i>Betweenness</i>
Centar za mirovne studije	24044,50
Kulturpunkt.hr	22624,51
GONG	16819,82
Udruga Antifašista grada Korčule	12714,70
Antifa Zagreb	7895,07
Gradjanska Akcija	7186,64
Protagora	6920,46
Center for Civil Courage	6832,24
Antifa Šibenik	5778,97
Lobotomizator	4844,78

Tablica 6.3.6 - Deset najvećih vrijednosti za metriku centraliteta *Betweenness* u tri najveće komponente - mreža stranica grupe L i N

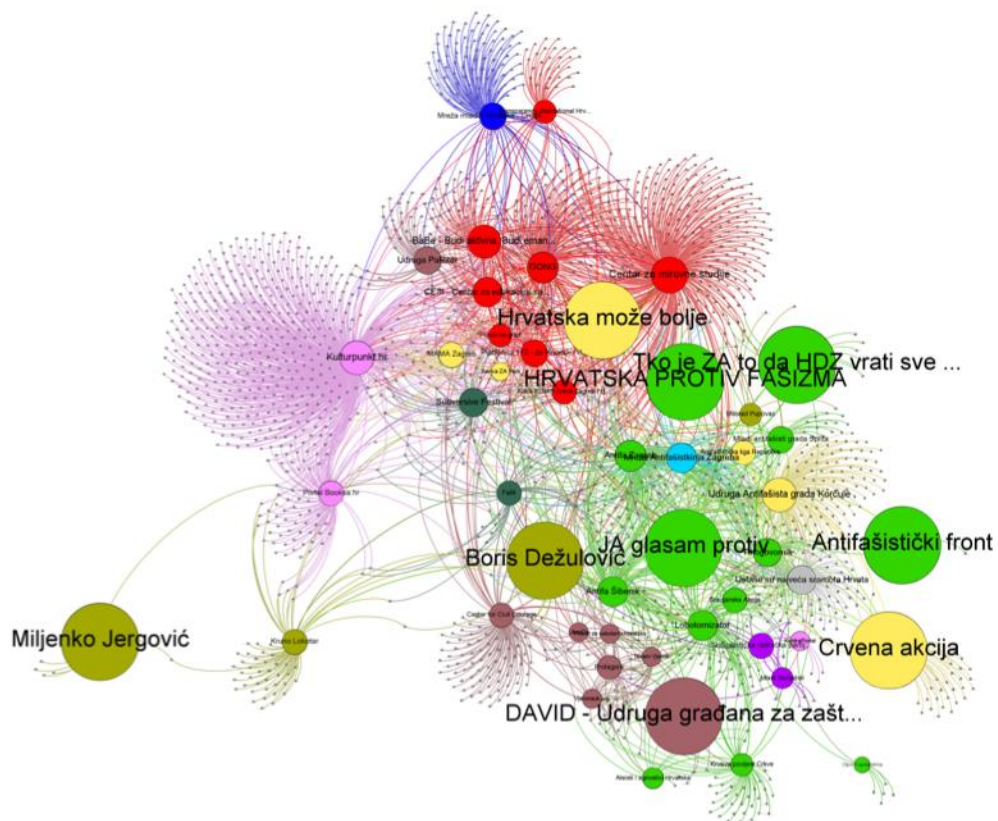


Slika 6.3.4 - Vizualizacija najveće komponente temeljem različitih podgrupa Facebook stranica (boje) i metrike centraliteta *Betweenness* (veličina entiteta) - mreža stranica grupe L i N

Metrika centraliteta *Closeness* za tri najveće komponente također sadrži *node-ove* koji se pojavljuju u sferi kompletne mreže. To su redom: „Udruga David“, „Ja glasam protiv“, „Boris Dežulović“, „Miljenko Jergović“, „Antifašistički front“, „Hrvatska protiv fašizma“ i „Tko je za to da HDZ vrati sve novce koje je ukrao“. Radi se o različitim tipovima stranica pri čemu najveći broj entiteta dolazi iz podgrupe koja se odnosi na nezavisnu propagandu (svijetlo zelena boja).

Stranica	<i>Closeness</i>
DAVID - Udruga građana za zaštitu ljudskih prava	1,0
JA glasam protiv	1,0
Hrvatska može bolje	1,0
Boris Dežulović	1,0
Crvena akcija	1,0
Antifašistički front	1,0
HRVATSKA PROTIV FAŠIZMA	1,0
Tko je ZA to da HDZ vrati sve novce koje je ukrao u zadnjih 20+ godina?	1,0
Miljenko Jergović	1,0
Centar za mirovne studije	0,46

Tablica 6.3.7 - Deset najvećih vrijednosti za metriku centraliteta *Closeness* u tri najveće komponente - mreža stranica grupe L i N




Slika 6.3.5 - Vizualizacija najveće komponente temeljem različitih podgrupa Facebook stranica (boje) i metrike centraliteta *Closeness* (veličina entiteta) - mreža stranica grupe L i N

PageRank na razini tri najveće komponente je jedina mjera koja nudi samo jedan entitet koji je u tom pogledu važan i na razini cjelokupne mreže za istoimenu metriku: ranije spomenutu stranicu naziva „U ime svake obitelji“ koja uopće nije bila predmetom analize. Također, udruga „Protagora“ (smeđa boja) se nalazi među deset najvećih vrijednosti za metriku *Betweenness* (na razini mreže), kao i za metriku *PageRank* (na razini tri najveće komponente). I u ovom slučaju javlja se niz entiteta koje nisu uzeti u razmatranje - uz već spomenutu udugu „U ime svake obitelji“ primjerice i poznati portal „SEEbiz“ ili stranica „Glasaj protiv“, ali i niz inozemnih stranica.

Stranica	<i>PageRank</i>
SEEbiz	0,00103
U ime svake obitelji	0,00097
Glasaj protiv	0,00090
David -Association of Citizens for Protection of Human Rights	0,00084
Internationalanswer.com/	0,00084
Ustaše su najveća sramota Hrvata	0,00083
europeans against the political system	0,00080
Protagora	0,00079
Capitalism GAME is OVER	0,00078
Kuća ljudskih prava Zagreb / Human Rights House Zagreb	0,00073

Tablica 6.3.8 - Deset najvećih vrijednosti za metriku centraliteta *PageRank* u tri najveće komponente - mreža stranica grupe L i N



Slika 6.3.6 - Vizualizacija najveće komponente temeljem različitih podgrupa Facebook stranica (boje) i metrike centraliteta *PageRank* (veličina entiteta) - mreža stranica grupe L i N


6.4. Utjecaj interesnih grupacija i primjeri iz prakse

Nakon provedene analize koja je uključivala zasebni proces vizualiziranja Facebook stranica grupe D te stranica grupe L i N moguće je donijeti neke generalne zaključke.

Prvo, analizom ranije nabrojanih stranica koje se pojavljuju kao bitne na razini mreže, ali i na razini najvećih komponenti neosporno je potvrđena važnost pojedinih *node-ova* u okvirima razmatranog modela (posebice u smislu distribucije informacija). Ipak, stranice koje na razini kompletne mreže ili najsnažnije komponente nisu obuhvaćene unutar top deset najvećih vrijednosti za pojedinu metriku često su se nalazile na proširenoj listi od top dvadeset entiteta što samo potvrđuje potrebu za daljnjom (još dubljom) analizom ove tematike. U tom kontekstu posebno je zanimljiv *PageRank* jer nam govori o tome koje stranice bi još trebalo uzeti u razmatranje bez obzira da li su namjerno (npr. nisu zadovoljile ranije tražene osnovne karakteristike) ili slučajno izostale iz procesa povlačenja podataka.

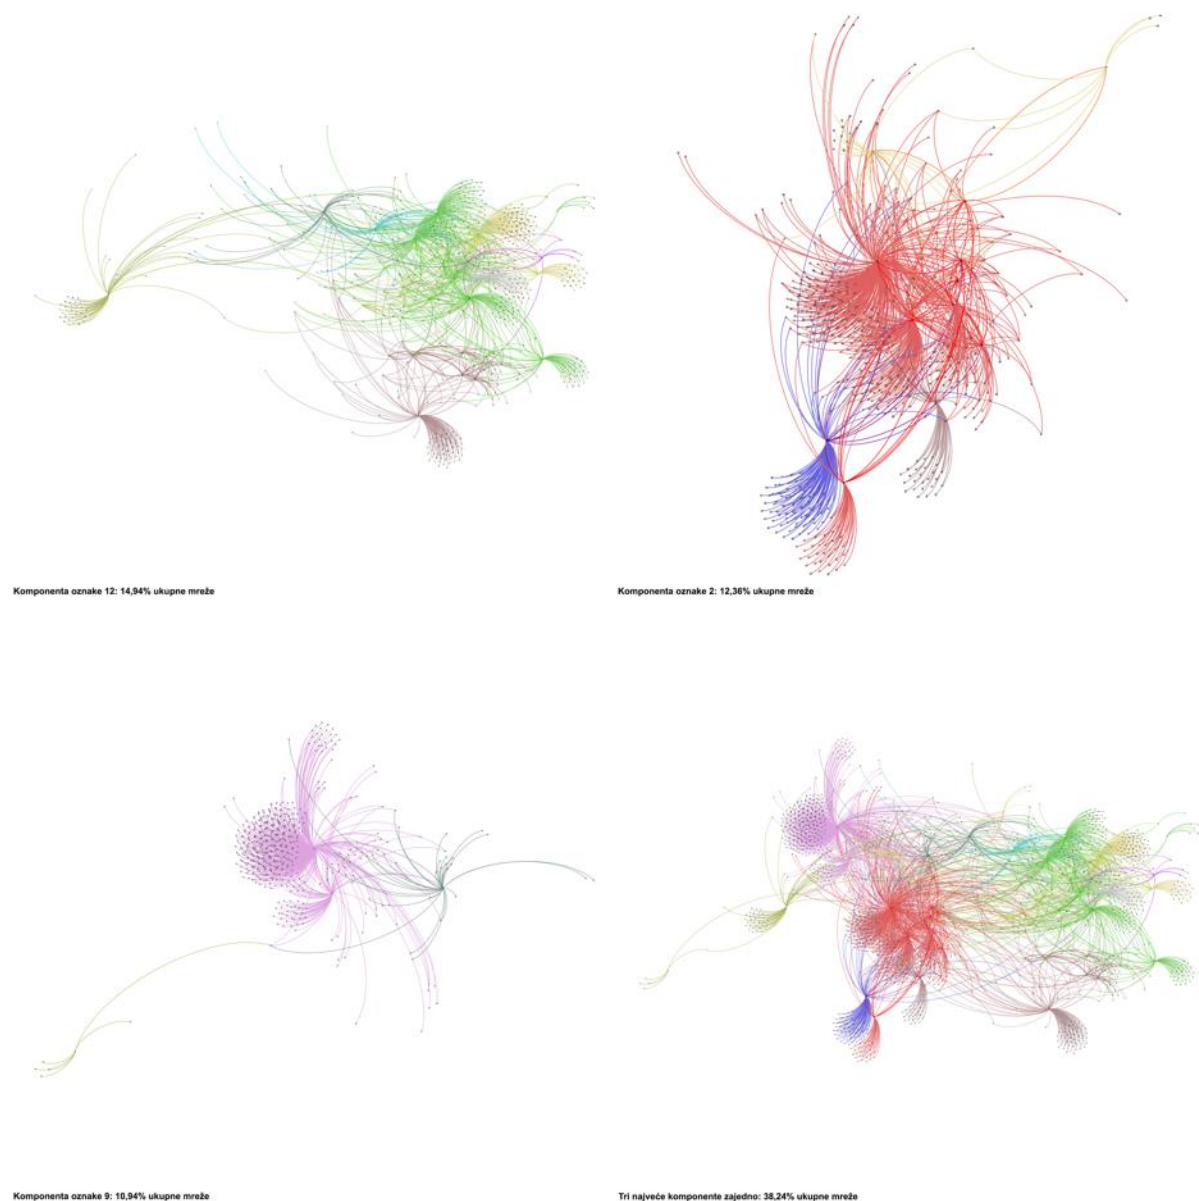
Drugo, gledajući svojstva mreže u cjelini, a posebice kroz prizmu razdiobe najvećih komponenti i podgrupe stranica koje se unutar istih nalaze došlo se do zanimljivih rezultata. Tako je već kroz teorijski dio spomenuto da upravo pojedine komponente predstavljaju grupirane entitete koji su međusobno jače povezani (umreženi) u odnosu na ostale.

U pogledu stranica grupe D pokazano je da od analiziranih entiteta primarno pro religijske interesne organizacije i mediji sa svojim odlaznim vezama ulaze u najveću komponentu koja nosi preko 20% mreže. Njihova nepobitna umreženost u tom smislu daje posve novi kontekst procesima u sklopu kojih se distribuiraju vijesti u informacijskom prostoru. Opisano je detaljno prikazano na slici 6.4.1 priloženoj u nastavku.



Slika 6.4.1 - Prikaz najveće komponente grupe stranica D - dominira povezanost pro religijskih interesnih organizacija (cijan boja) i medija (narančasta boja)

Gledajući kombinaciju stranica grupe L i N nije analizirana samo najveća komponenta već tri najveće zbog sličnog udjela u ukupnoj mreži. Kako bi se dobio još jasniji uvid u vrstu analiziranih stranica koje dominiraju pojedinim komponentama na narednoj slici 6.4.2 pokazane su tri najveće komponente zasebno te sve tri zajedno (kao što su bile i ranije analizirane). Lako je uočiti da prvom najvećom dominira zelena boja (nezavisna propaganda), drugom najvećom crvena (Platforma 112), a trećom najvećom roza (mediji). Takva međusobna veća direktna ili indirektna povezanost i u ovom slučaju daje značajan kontekst propagaciji informacija.



Slika 6.4.2 - Razdvojeni i zajednički prikaz tri najveće komponente grupe stranica L i N - dominira povezanost stranica nezavisne propagande (zelena boja), interesnih organizacija Platforma 112 (crvena boja) i medija (roza boja)

Uspoređujući izrečene činjenice između kombinacije stranica grupe D te grupe L i N lako je doći do zaključka da zajednička karakteristika koja se javlja u oba slučaja jest upravo veća izražena direktna i indirektna povezanost medija i različitih interesnih organizacija. S obzirom da većina analiziranih entiteta takvog tipa naglašava svoju nezavisnost u djelovanju, vjerodostojnost takvih tvrdnji postaje suspektna.

Kako ovi zaključci ne bi ostali samo u domeni teorije potrebno ih je dodatno potkrijepiti aktualnim primjerima iz prakse. Ranije je spomenuta presuda Slobodanu Praljku krajem studenog 2017. nakon čega je u sklopu suprotstavljanja političkih snaga lijevog i desnog spektra došlo do rušenja različitih Facebook stranica. Učinjenom naknadnom provjerom početkom veljače 2018. ustanovljeno je da niz stranica koje su bile predmetom analize više ne postoji.

Za grupu D to su (osim namjerno ugašene duplikat stranice stranke AHSP):

- Croative.net, Maxportal.hr, Hrvatsko Obrambeno Štivo (Mediji)
- Partizani i komunisti su najveća sramota Hrvata, Građanska Akcija, PRIZNAJEM! HRVAT SAM, ZABORAVLJENI SINOVI DOMOVINSKOG RATA, Za Dom Spremni (Nezavisna propaganda)

Ranije je kroz analizu kompletne mreže ustanovljeno da neki od navedenih entiteta drže visoke pozicije u smislu vrijednosti pojedinih metrika. Za *Betweenness* je to stranica „Partizani i komunisti su najveća sramota Hrvata“, a za *Closeness* „ZABORAVLJENI SINOVI DOMOVINSKOG RATA“ i „Za Dom Spremni“.


Za kombinaciju grupa L i N to su sljedeće stranice:

- Mladi antifašisti grada Splita, Antifa Zagreb, Antifašistički front, Gradjanska Akcija, Racionalist (Nezavisna propaganda)

U ovom slučaju se stranica „Antifašistički front“ pojavljuje kao bitna na razini cijele mreže (ali i tri najveće komponente) u pogledu mjere *Closeness*, a stranice „Antifa Zagreb“ i „Gradjanska akcija“ kao bitne u smislu mjere *Betweenness* i to na razini tri najveće komponente.

Ako pak gledamo period siječnja i veljače 2018. godine u informacijskom prostoru Republike Hrvatske zamijećena je značajna pojava vijesti koji se vežu uz

ratifikaciju Istanbulske konvencije čija je agenda primarno posvećena sprečavanju nasilja nad ženama.⁸² Navedeno se javlja kao još jedan odličan primjer propagacije vijesti kroz prizmu informacijskog ratovanja jer dvije glavne analizirane grupe stranica zastupaju dijametralno suprotna stajališta u svezi moguće ratifikacije konvencije od strane RH. Dok snage lijevog političkog spektra podržavaju istu, interesne organizacije navedene u grupi D žestoko se protive ratifikaciji pri čemu ističu štetnost sakrivenih propagandnih aktivnosti vezanih uz rodnu ideologiju koja je također sadržana u samoj konvenciji, a promiče ideju spola kao društvenog konstrukta koji promiče diskriminaciju.⁸³ Tako je primjerice pokrenuto niz inicijativa koje ističu negativan sentiment prema navedenoj temi, uključujući i stranicu „Istina o Istanbulskoj“.⁸⁴ Korištenjem takozvane „retrogradne“ tehnike praćenja medija, odnosno obuhvaćanjem objava iz različitih internet izvora za period između 15.01. i 15.02.2018. uočen je značajan broj vijesti vezanih uz Istanbulsku konvenciju (preko 400). Budući da vijesti nisu praćene u realnom vremenu broj objava nije točan već je vjerojatno i mnogo veći no navedene brojke na slici 6.4.3 dovoljno zorno ukazuju na generalne trendove.



Slika 6.4.3 - Trend objava na hrvatskom internet prostoru za ključnu riječ "Istanbulska konvencija" u periodu 15.01.-15.02.2018. dobiven korištenjem alata Mediatoolkit

⁸² Council Of Europe. *Istanbul Convention*.

<https://www.coe.int/en/web/istanbul-convention/home> (16.02.2018.)

⁸³ Wikipedia. *Rodna ideologija*.

https://hr.wikipedia.org/wiki/Rodna_ideologija (16.02.2018.)

⁸⁴ Istina o Istanbulskoj. *Građanska inicijativa istina o Istanbulskoj*.

<http://www.istinaoistanbulskoj.info/gradanska-inicijativa> (16.02.2018.)

Ako navedeno pogledamo u kontekstu modela analiziranog kroz ovaj rad, odnosno djelovanja Facebook stranica moguće je zamijetiti niz objava i moguće koordinirano djelovanje pojedinih stranica koje su analizom na razini pojedinih entiteta označene bitnima. U pogledu grupe D izdvojeni su primjeri koji se nadovezuju na izrazito povezane vrste stranica kao što su pro religijske organizacije („U ime obitelji“) i mediji („Narod.hr“), a koje se protive ratifikaciji konvencije zbog promicanja rodne ideologije (slika 6.4.4). Dijametralno suprotna propagacija vijesti vidljiva je kod povezane vrste stranica kao što su Platforma 112 („Centar za mirovne studije“) i Mediji („Libela.org“) - slika 6.4.5.



Slika 6.4.4 - Facebook objave stranica "U ime obitelji" i "Narod.hr"



Slika 6.4.5 - Facebook objave stranica "Centar za mirovne studije" i "Libela.org"

7. Preporuke

Kroz rad se provlačila ideja razvijanja baznog konceptualnog modela koji se uz manje korektivne mjere može preoblikovati kako bi nadograđen poslužio u svrhu analize i vizualizacije većih količina podataka. Više puta spomenuta ograničenja koja su utjecala na izradu jedan su od razloga zašto je rad postavljen unutar ovakvih okvira. Navedeno podrazumijeva da se pojedini procesi (kao i cijeli pretpostavljeni model općenito) mogu podići na razinu više. To bi se moglo postići djelovanjem u nekoliko različitih smjerova.


1. Dostupnost podataka. Jedan od glavnih preduvjeta za tako nešto bi bila veća raspoloživost podataka za obradu, prvenstveno podataka koji se odnose na osobne profile. U tom slučaju bi i točnost predviđanja modela svakako progresivno rasla. Tako nešto je moguće ostvariti na razne načine, jedan od primjera je i kupnja podataka od tzv. podatkovnih brokera. S druge strane i postojećim modelom je moguće obuhvatiti još veći broj stranica, što bi doprinijelo ukupnoj veličini mreže.
2. Dodatna istraživanja koja se baziraju na ovom modelu. Tako je moguće analizirati povezanost interesnih grupacija u mnogobrojnim drugim kombinacijama koje u radu nisu obrađene. Isto vrijedi i za analizu različitih atributa koje stranice sadrže - npr. broj *fan-ova*.

Jedna od opcija jest vizualizacija cijele mreže putem takozvanog bow-tie dijagrama.⁸⁵ Navedeni model pruža prikaz mreže putem pet različitih vrsti komponenti. To su redom: „SCC“ (eng. *strongly connected component*), odnosno komponenta koja sadrži entitete koja mogu doseći bilo koji drugi entitet putem usmjerenih veza, „IN“ komponenta (može doseći entitete u SCC), „OUT“ komponenta (entitete iz te grupe je moguće doseći samo iz SCC), komponenta „*Tendrils and tubes*“ (čvorovi povezani samo s IN i/ili OUT komponentom) te „*Disconnected*“ komponenta koja sadrži entitete koji su izolirani.

Putem takvog modela moguće je lakše prognozirati širenje informacija na razini cijele mreže, a jedan od programskih alata koji podržavaju upravo

⁸⁵ ADAMIC, L. *Introductory social network analysis with Pajek*. Ann Arbor, MI: University of Michigan, 2008., str. 19.

opisani model je i slovenski Pajek. Ako bi primjerice htjeli biti proaktivni u smislu upravljanja informacijama takvom analizom bi mogli saznati putem kojih čvorova je potrebno plasirati neku vijest. Tada bi mogli ostvariti najveći učinak ovisno o ciljanoj podgrupi stranica ili pak političkoj orijentaciji, a da istodobno zaobiđemo neke druge entitete u tom procesu ukoliko se za to ukaže potreba. Isto važi i za obrnutu situaciju u kojoj smo pasivni promatrači i želimo predvidjeti razvoj različitih scenarija.



Slika 6.4.1 - Prikaz bow-tie modela
Izvor: ADAMIC, L. *Introductory social network analysis with Pajek*.
Ann Arbor, MI: University of Michigan, 2008., str. 19.

Nadalje, potrebno je spomenuti i još jednu mjeru centraliteta - Laplace (eng. *Laplacian centrality*).⁸⁶ Ista se javlja kao metrika između onih koje se izračunavaju na razini pojedinih entiteta te onih koje važe za kompletnu mrežu. U prijevodu, Laplace govori o važnosti susjeda pojedinih entiteta. Ista dolazi do izražaja kod mreža koje imaju različitu težinu veza pa bi tek kod nadograđenog modela imala više smisla (npr. u slučaju dvomodalne mreže koja sadrži profile i stranice pri čemu sve veze nemaju identičan iznos težine veze od 1,0).

⁸⁶ QI, X., FULLER, E., WU, Q., WU, Y., ZHANG, C-Q. *Laplacian centrality: A new centrality measure for weighted networks*. New York: Elsevier, Information Sciences, Vol. 194, 240-253, 2012., str. 240.

Prošireno istraživanje je moguće raditi i temeljem analize komentara, a što je već navedeno kao mogućnost u poglavlju o Facebook stranicama. Budući da sve komentare i *like-ove* napravljene od strane osobnih profila na javnim stranicama mogu vidjeti svi, razina dostupnosti takvih podataka je visoka pa se i mreže temeljene na takvim značajkama zanimljive za potencijalnu analizu. Pri tome valja naglasiti da se veze stvaraju primjerice između osoba koje su komentirale, *like-ale* ili dijelile identičan sadržaj, ovisno o tome što odaberemo kao cilj analize. Pri tome valja naglasiti da komentar nosi veći ponder od *like-a*. Ako pravilno provedemo analizu moguće je uočiti potencijalne uzorke u smislu obrazaca ponašanja - npr. komentiranje određenog sadržaja uvijek istih ili sličnih osoba na stranicama različitih portala pri čemu možemo identificirati ključne profile te ih potencijalno neutralizirati ili onemogućiti. Primjer za to može biti komentiranje ranije spomenutih *troll-ova* ili *bot-ova* u političkim kampanjama koji često koordinirano napadaju i diskreditiraju neku političku opciju te zastupaju određenu agendu kroz kreiranje komentara na objavljenim člancima unutar stranica na društvenim mrežama.

3. Kao treća stavka javlja se nadogradnja u vidu softverske podrške. Korišteni alati imaju svoja ograničenja, a od kojih su neka spomenuta u slučaju Excel nadogradnje NodeXL koja je stvarala određenih problema prilikom povlačenja podataka. To nije predstavljalo jedinu otežavajuću okolnost budući da je i glavni korišteni alat Gephi pokazao određene nedostatke. To je primjerice nemogućnost direktnog prebacivanja podataka između različitih radnih površina ili pak nemogućnost čuvanja povijesti korištenih boja prilikom vizualizacija mreža. U tom smislu postoje komercijalni i/ili napredniji alati na koje bi valjalo obratiti pozornost.

Priprema i obrada podataka bi se prije samih vizualizacija mogla vršiti u tzv. NetworkX *libraryu* za programski jezik Python.⁸⁷ Prednost takve obrade dolazi do izražaja ako je potrebno manipulirati većom količinom podataka, posebice ako navedeno traži nestandardizirana rješenja koja je moguće dodatno isprogramirati. Nadalje, automatizacija prikupljanja podataka također se javlja kao prirodno rješenje - posebice automatizacija prikupljanja u realnom

⁸⁷ NetworkX. *NetworkX - Software for complex networks*. <https://networkx.github.io/> (02.01.2018.)

vremenu. Kao primjer se može izdvojiti upotreba GraphX sučelja unutar Apache sustava za obradu velikih količina podataka u realnom vremenu.⁸⁸ Pri tome GraphX služi za obradu podataka baziranih na grafovima te izračune i vizualizacije slične onima prezentiranim u prethodnim poglavljima. Analiza podataka u realnom vremenu dobiva na važnosti ako u obzir uzmemo činjenicu da su neke stranice u razdoblju izrade rada bile srušene pa donošenje zaključaka temeljem pravovremeno sakupljenih podataka postaje svrsishodno.

4. Analiza podataka s ostalih društvenih mreža, posebice Twittera, ali i drugih utjecajnih mreža poput sve popularnijeg Instagrama. U tom pogledu Twitter je posebno interesantan s obzirom na već spomenuti fleksibilniji API protokol u odnosu na Facebook.

Vizualizacije temeljene na podacima koje se sastoje od entiteta s društvenih mreža nisu jedini mogući predmet analize, posebice ne u kontekstu tematike koja se odnosi na analizu tijeka informacija. Aspekti iz kojih se tada može pristupiti problematici mogu primjerice proizlaziti iz proučavanje tijeka kapitala (npr. financiranje interesnih organizacija iz odrađene Facebook analize) ili pak proučavanjem aktivnosti medija između *online* i *offline* okruženja. Primjera je mnogo.

⁸⁸ Apache Software Foundation. *GraphX*. <https://spark.apache.org/graphx/> (02.01.2018.)

Zaključak

Referirajući se na uvodne pretpostavke i kompletni proces izrade nameće se zaključak da u uvjetima brzih i kompleksnih promjena često treba pribjeći kreativnim rješenjima koja se na prvu ne čine toliko očitima. Izvođenje rada temeljem javno dostupnih podataka tako istovremeno može biti prednost i nedostatak. Bez obzira na sve, kroz prethodna poglavlja izložen je okvir koji u svakom pogledu može biti nadograđen u više smjerova. Isti predstavlja kvalitetnu osnovu za daljnje istraživačke analize društvenih mreža korištenjem SNA analize i vizualizacije podataka.

Gledajući stvari iz takvog aspekta rad je postavljen na način da odabirom teme poboljšava svijest i percepciju o obrađivanoj tematici. U dinamičnosti današnjeg svijeta propagandna izloženost stanovnika jedne države raznolikim interesnim sferama je izrazito složena. Kroz dosadašnja poglavlja pokušalo se razlučiti i pojasniti samo jedan manji dio procesa kojeg čine informacijski tokovi, a neosporno je da propagiranje vijesti i različitih drugih informacija u kontekstu informacijskog ratovanja predstavlja izrazito široko područje za istraživanje. Tako definiran informacijski prostor u kojem tehnologija putem samog jednog kanala (društvenih mreža) služi za ostvarivanje različitih interesnih ciljeva zanimljiv je predmet proučavanja. Pored navedenog, jedan od razloga zašto se pristupilo razradi ove problematike jest i relativno malen broj objavljenih radova na sličnu temu.

Ono što je navedeno u uvodu kroz rad je dobilo svoju potvrdu. Razvoj temeljnih pretpostavki koje određuju pravce kretanja istraživačke analize, povlačenje podataka i njihova obrada čine najveći dio posla. Iako je rad u svojem naslovu istaknuo važnost vizualizacija podataka, postupci koji dovode do istih su dugotrajni tako da sami finalni proizvod predstavlja tek manji dio rada.

Klasičan analitički pristup podrazumijeva provođenje različitih izračuna koji bi trebali osnažiti svijest donositelja odluka o zbivanjima u njegovoj sferi interesa te poboljšati proces donošenja odluka. Takav pristup koji za prikaz rezultata koristi tabličnu strukturu može najčešće samo izrazito stručnim korisnicima biti svrsishodan. S druge strane, ovim se radom između ostalog pokazalo da upravo napredne vizualizacije rade prevagu te olakšavaju donošenje zaključaka, bilo od strane naprednih stručnjaka ili pak nekih drugih korisnika. Vizualizacije tako neosporno oplemenjuju

percepciju i omogućuju neusporedivo viši stupanj razumijevanja nepreglednih količina analiziranih podataka te upravo u tom finalnom dijelu analize leži ona dodana vrijednost koju je nemoguće opovrgnuti.

Konačno, korištenje skupa tehnika prezentiranih u radu omogućuje nam ostvarivanje pretpostavljenih ciljeva, bilo da trebamo upravljati vlastitim informacijskim tokovima ili neutralizirati tuđe nepoželjne. Pojednostavljeno rečeno - omogućuje da bolje razumijemo tokove, a sve kako bi na njih mogli reagirati na najprikladniji način. To je posebno bilo vidljivo kod analize različito grupiranih Facebook stranica prilikom čega se došlo do zanimljivih saznanja u smislu njihove snage i međusobne isprepletenosti. Takvi rezultati zasigurno mogu imati određene indikacije u pogledu djelovanja različitih interesnih organizacija unutar društvenog sustava Republike Hrvatske. Navedeno može pomoći različitom broju zainteresiranih strana, od državnih tijela (obavještajne službe, policija) u većoj kontroli nad procesima stalnih društvenih promjena pa do znanstvenika koji izučavaju slična područja interesa.

Popis slika

Slika 4.1.1 - Model koji sadrži samo međusobno povezane profile	21
Slika 4.1.2 - Model koji sadrži profile koji slijede određene stranice i informacije o međusobnoj povezanosti tih profila	22
Slika 4.1.3 - Model koji sadrži stranice, administratore tih stranica i profile s kojima su administratori povezani	22
Slika 4.1.4 - Model koji sadrži profile, stranice i grupe te informacije o njihovoj međusobnoj povezanosti.....	23
Slika 4.2.1 - Shematski prikaz grupiranja Facebook stranica s istaknutim ukupnim brojem stranica.....	29
Slika 5.1.1 - NodeXL - izgled osnovnog sučelja	45
Slika 5.1.2 - NodeXL - Odabrane postavke za povlačenje podataka	46
Slika 5.2.1 - NodeXL - postupak brisanja mreže drugog stupnja.....	48
Slika 5.2.2 - Notepad++ - ispravak greške - transformacija iz neusmjerene u usmjerenu mrežu	50
Slika 5.2.3 - Notepad++ - ispravak greške - promjena numeričke varijable iz <i>string</i> u <i>integer</i>	50
Slika 5.2.4 - Gephi - postupak <i>importa</i> mreže u .graphml formatu	51
Slika 6.1.1 - Gephi - izgled osnovnog sučelja.....	52
Slika 6.2.1 - Vizualizacija mreže temeljem različitih podgrupa Facebook stranica (boje) i metrike centraliteta <i>Betweenness</i> (veličina entiteta) - mreža stranica grupe D	58
Slika 6.2.2 - Vizualizacija mreže temeljem različitih podgrupa Facebook stranica (boje) i metrike centraliteta <i>Closeness</i> (veličina entiteta) - mreža stranica grupe D .	60
Slika 6.2.3 - Vizualizacija mreže temeljem različitih podgrupa Facebook stranica (boje) i metrike centraliteta <i>PageRank</i> (veličina entiteta) - mreža stranica grupe D .	62
Slika 6.2.4 - Vizualizacija najveće komponente temeljem različitih podgrupa Facebook stranica (boje) i metrike centraliteta <i>Betweenness</i> (veličina entiteta) - mreža stranica grupe D	64
Slika 6.2.5 - Vizualizacija najveće komponente temeljem različitih podgrupa Facebook stranica (boje) i metrike centraliteta <i>Closeness</i> (veličina entiteta) - mreža stranica grupe D	66

Slika 6.2.6 - Vizualizacija najveće komponente temeljem različitih podgrupa Facebook stranica (boje) i metrike centraliteta <i>PageRank</i> (veličina entiteta) - mreža stranica grupe D	68
Slika 6.3.1 - Vizualizacija mreže temeljem različitih podgrupa Facebook stranica (boje) i metrike centraliteta <i>Betweenness</i> (veličina entiteta) - mreža stranica grupe L i N.....	72
Slika 6.3.2 - Vizualizacija mreže temeljem različitih podgrupa Facebook stranica (boje) i metrike centraliteta <i>Closeness</i> (veličina entiteta) - mreža stranica grupe L i N	74
Slika 6.3.3 - Vizualizacija mreže temeljem različitih podgrupa Facebook stranica (boje) i metrike centraliteta <i>PageRank</i> (veličina entiteta) - mreža stranica grupe L i N	76
Slika 6.3.4 - Vizualizacija najveće komponente temeljem različitih podgrupa Facebook stranica (boje) i metrike centraliteta <i>Betweenness</i> (veličina entiteta) - mreža stranica grupe L i N	78
Slika 6.3.5 - Vizualizacija najveće komponente temeljem različitih podgrupa Facebook stranica (boje) i metrike centraliteta <i>Closeness</i> (veličina entiteta) - mreža stranica grupe L i N	80
Slika 6.3.6 - Vizualizacija najveće komponente temeljem različitih podgrupa Facebook stranica (boje) i metrike centraliteta <i>PageRank</i> (veličina entiteta) - mreža stranica grupe L i N	82
Slika 6.4.1 - Prikaz najveće komponente grupe stranica D - dominira povezanost pro religijskih interesnih organizacija (cijan boja) i medija (narančasta boja)	84
Slika 6.4.2 - Razdvojeni i zajednički prikaz tri najveće komponente grupe stranica L i N - dominira povezanost stranica nezavisne propagande (zelena boja), interesnih organizacija Platforma 112 (crvena boja) i medija (roza boja).....	85
Slika 6.4.3 - Trend objava na hrvatskom internet prostoru za ključnu riječ "Istanbulska konvencija" u periodu 15.01.-15.02.2018. dobiven korištenjem alata Mediatoolkit	87
Slika 6.4.4 - Facebook objave stranica "U ime obitelji" i "Narod.hr"	88
Slika 6.4.5 - Facebook objave stranica "Centar za mirovne studije" i "Libela.org" ...	88
Slika 6.4.1 - Prikaz bow-tie modela Izvor: ADAMIC, L. <i>Introductory social network analysis with Pajek</i> . Ann Arbor, MI: University of Michigan, 2008., str. 19.	90

Popis tablica

Tablica 2.3.1 - Opis mjera centraliteta na razini pojedinačnih entiteta.....	6
Tablica 4.2.1 - Koraci u strukturiranju podataka prema zadanom modelu.....	27
Tablica 4.2.2 - Informacije o broju stranica i broju <i>fan-ova</i> unutar pojedine podgrupe Facebook stranica	28
Tablica 4.3.1 - Grupa stranica "N - Manifestacije"	30
Tablica 4.3.2 - Grupa stranica "N - Sindikati i savezi"	30
Tablica 4.3.3 - Grupa stranica "D - Interesne organizacije - pro religijske".....	31
Tablica 4.3.4 - Grupa stranica "D - Mediji"	32
Tablica 4.3.5 - Grupa stranica "D - Političke stranice"	33
Tablica 4.3.6 - Grupa stranica "D - Nezavisna propaganda"	34
Tablica 4.3.7 - Grupa stranica "D - Osobe"	35
Tablica 4.3.8 - Grupa stranica "L - Interesne organizacije - anti religijske".....	36
Tablica 4.3.9 - Grupa stranica "L - Interesne organizacije - ostale".....	37
Tablica 4.3.10 - Grupa stranica "L - Interesne organizacije - ostale - Platforma 112 - za Hrvatsku vladavine prava"	39
Tablica 4.3.11 - Grupa stranica "L - Mediji"	40
Tablica 4.3.12 - Grupa stranica "L - Mediji - Mreža emancipacije E-net".....	41
Tablica 4.3.13 - Grupa stranica "L - Nezavisna propaganda"	42
Tablica 4.3.14 - Grupa stranica "L - Osobe"	43
Tablica 4.3.15 - Grupa stranica "L - Političke stranke"	44
Tablica 5.1.1 - Informacije o vremenskim razdobljima povlačenja podataka s interneta	46
Tablica 6.2.1 - Popis komponenti i njihov udio u ukupnoj mreži - mreža stranica grupe D	56
Tablica 6.2.2 - Legenda boja koja označava podgrupe Facebook stranica - mreža stranica grupe D.....	56
Tablica 6.2.3 - Deset najvećih vrijednosti za metriku centraliteta <i>Betweenness</i> - mreža stranica grupe D	57
Tablica 6.2.4 - Petnaest najvećih vrijednosti za metriku centraliteta <i>Closeness</i> - mreža stranica grupe D	59

Tablica 6.2.5 - Deset najvećih vrijednosti za metriku centraliteta <i>PageRank</i> - mreža stranica grupe D	61
Tablica 6.2.6 - Šest najvećih vrijednosti za metriku centraliteta <i>Betweenness</i> u najvećoj komponenti - mreža stranica grupe D	63
Tablica 6.2.7 - Šest najvećih vrijednosti za metriku centraliteta <i>Closeness</i> u najvećoj komponenti - mreža stranica grupe D	65
Tablica 6.2.8 - Deset najvećih vrijednosti za metriku centraliteta <i>PageRank</i> u najvećoj komponenti - mreža stranica grupe D	67
Tablica 6.3.1 - Popis komponenti i njihov udio u ukupnoj mreži - mreža stranica grupe L i N.....	70
Tablica 6.3.2 - Legenda boja koja označava podgrupe Facebook stranica - mreža stranica grupe L i N	70
Tablica 6.3.3 - Deset najvećih vrijednosti za metriku centraliteta <i>Betweenness</i> - mreža stranica grupe L i N	71
Tablica 6.3.4 - Dvanaest najvećih vrijednosti za metriku centraliteta <i>Closeness</i> - mreža stranica grupe L i N	73
Tablica 6.3.5 - Deset najvećih vrijednosti za metriku centraliteta <i>PageRank</i> - mreža stranica grupe L i N	75
Tablica 6.3.6 - Deset najvećih vrijednosti za metriku centraliteta <i>Betweenness</i> u tri najveće komponente - mreža stranica grupe L i N	77
Tablica 6.3.7 - Deset najvećih vrijednosti za metriku centraliteta <i>Closeness</i> u tri najveće komponente - mreža stranica grupe L i N	79
Tablica 6.3.8 - Deset najvećih vrijednosti za metriku centraliteta <i>PageRank</i> u tri najveće komponente - mreža stranica grupe L i N	81

Literatura

- [1] Facebook. *Gephi Group*. <https://www.facebook.com/groups/gephi/> (06.02.2018.)
- [2] Večernji list. *Što je to hibridni rat i vodi li se on u Hrvatskoj?*
<https://www.vecernji.hr/vijesti/sto-je-to-hibridni-rat-i-vodi-li-se-on-u-hrvatskoj-1210522> (30.11.2017.)
- [3] NATO Review. *Hybrid war - does it even exist?*
<https://www.nato.int/docu/review/2015/Also-in-2015/hybrid-modern-future-warfare-russia-ukraine/EN> (01.12.2017.)
- [4] RENZ, B., SMITH, H. *Russia And Hybrid Warfare - Going Beyond The Label*. Helsinki: Kikimora Publications, 2016.
- [5] Global Information Assurance Certification. *Information Warfare*.
<https://www.giac.org/paper/gsec/1870/information-warfare/103284> (30.11.2017.)
- [6] R. GERY, W., LEE, S., NINAS, J. *Information Warfare in an Information Age*. Washington, DC: NDU Press, Joint Force Quarterly, Vol. 85, 22-29, 2017.
- [7] The Intercept. *The New Information Warfare*.
<https://theintercept.com/2017/11/25/information-warfare-social-media-book-review-gaza> (01.12.2017.)
- [8] HANSEN, D., SHNEIDERMAN, B., SMITH, M. *Analyzing Social Media Networks with NodeXL*. Burlington, MA: Morgan Kaufmann, Kindle Edition, 2011.
- [9] Facebook Code. *Scaling the Facebook data warehouse to 300 PB*.
<https://code.facebook.com/posts/229861827208629/scaling-the-facebook-data-warehouse-to-300-pb/> (06.02.2018.)
- [10] KOPAL, R., KORKUT, D., KRNJAŠIĆ, S. *Analiza (socijalnih) mreža: praktična primjena*. Zagreb: IN2data d.o.o. / Visoko učilište Algebra, 2016.
- [11] Cambridge Intelligence. *EigenCentrality & PageRank*.
<https://cambridge-intelligence.com/eigencentrality-pagerank/> (04.01.2018.)
- [12] DE NOOY, W., MRVAR, A., BATAGELJ, V. *Exploratory Social Network Analysis with Pajek (Structural Analysis in the Social Sciences)*. Cambridge: Cambridge University Press, Kindle Edition, 2011.
- [13] Github. *Modularity Algorithm*.
<https://github.com/gephi/gephi/wiki/Modularity> (04.01.2018.)

- [14] Google Sites. *Louvain method: Finding communities in large networks*.
<https://sites.google.com/site/findcommunities/> (04.01.2018.)
- [15] FEW, S. *Now You See It*. Oakland, CA: Analytics Press, 2009.
- [16] SHNEIDERMAN, B. *The Eyes Have It: A Task By Data Type Taxonomy For Information Visualizations*. Los Alamitos, CA: IEEE Computer Society Press, IEEE Symposium on Visual Languages, 336-343, 1996.
- [17] KUNIĆ, Z. *Vizualizacijski softverski alati u marketingu: Analitička navigacija*, 6. predavanje. Zagreb: Visoko učilište Algebra, 2017.
- [18] Jutarnji list. *Putinov hibridni rat: i Hrvatska traži pomoć EU u suzbijanju ruske propagande*.
<https://www.jutarnji.hr/vijesti/hrvatska/putinov-hibridni-rat-i-hrvatska-trazi-pomoc-eu-u-suzbijanju-ruske-propagande-suoceni-smo-s-velikom-i-vrlo-sofisticiranom-kampanjom-dezinformiranja/6678054/> (13.12.2017.)
- [19] European External Action Service (EEAS). *Strategic Communications Division (StratCom)*.
https://eeas.europa.eu/headquarters/headquarters-homepage_en/100/Strategic%20Communications (13.12.2017.)
- [20] Eastern Partnership Civil Society Forum (EaP CSF). *Eastern Partnership: Battleground of Russia's Disinformation War*.
<https://eap-csf.eu/eastern-partnership-battleground-of-russias-disinformation-war/> (14.12.2017.)
- [21] Collins Dictionary. *The Collins Word of the Year 2017 is...*
<https://www.collinsdictionary.com/woty> (08.02.2018.)
- [22] The Guardian. *How Russia used social media to divide Americans*.
<https://www.theguardian.com/us-news/2017/oct/14/russia-us-politics-social-media-facebook> (08.02.2018.)
- [23] Techopedia. *What is a Troll?*
<https://www.techopedia.com/definition/429/troll> (09.02.2018.)
- [24] Techopedia. *What is a Socialbot?*
<https://www.techopedia.com/definition/27811/socialbot> (08.02.2018.)
- [25] Jutarnji list. *Intervju s ministrom unutarnjih poslova dr. sc. Davorom Božinovićem*.
<https://www.jutarnji.hr/vijesti/hrvatska/bozinovic-plenkovicevoj-oporbi-u-hdz-u->

- prije-njega-nismo-mogli-realizirati-vec-dobivenu-izbornu-bitku-a-i-na-vlasti-smo-trajali-koliko-smo-trajali/6888870/ (19.01.2018.)
- [26] Nova TV. *Završen braniteljski prosvjed u Savskoj.*
<https://dnevnik.hr/vijesti/hrvatska/završen-braniteljski-prosvjed-u-savskoj---434862.html> (14.12.2017.)
- [27] Hrvatska može bolje. *Tko podržava ovu inicijativu?*
<http://hrvatskamozebolje.org/tko-podrzava-ovu-inicijativu> (12.12.2017.)
- [28] Vlada Republike Hrvatske. *Financiranje vjerskih zajednica u Republici Hrvatskoj - odgovor na zastupničko pitanje Anke Mrak - Taritaš.*
<https://vlada.gov.hr/UserDocsImages//Sjednice/2017/12%20prosinac/70%20sjednica%20VRH//70%20-%2023%20a.pdf> (19.01.2018.)
- [29] Vlada Republike Hrvatske. *Godišnji plan natječaja tijela državne uprave za 2017. godinu.*
<https://udruga.gov.hr/godisnji-plan-natjecaja-javnih-poziva-i-drugih-programa-financiranja-projekata-i-programa-organizacija-civilnog-drustva-u-2017-godini/4004> (19.01.2018.)
- [30] The Dubrovnik Times. *The social media scene in Croatia in 2018. - Facebook dominates, Instagram rising, Twitter still locked its cage.*
<http://www.thedubrovniktimes.com/lifestyle/feature/item/3854-the-social-media-scene-in-croatia-in-2018-facebook-dominates-instagram-rising-twitter-still-locked-its-cage> (09.02.2018.)
- [31] Twitter Developers. *Twitter Developer Platform.*
<https://developer.twitter.com/> (09.02.2018.)
- [32] Science Magazine. *Social media 'bots' tried to influence the U.S. election. Germany may be next.*
<http://www.sciencemag.org/news/2017/09/social-media-bots-tried-influence-us-election-germany-may-be-next> (09.02.2018.)
- [33] RTL Televizija. *"Rat" na Facebooku: blokirani desničari koji veličaju generala Praljka - odgovorili prijavama protiv ljevičara pa mreža blokirala i njih.*
<https://vijesti.rtl.hr/novosti/hrvatska/2754735/rat-na-facebooku-blokirani-desnicari-koji-velicaju-general-praljka-odgovorili-prijavama-protiv-ljevicara-pa-mreza-blokirala-i-njih/> (19.01.2018.)
- [34] Facebook Help Center. *Your Profile and Settings.*
<https://www.facebook.com/help/239070709801747> (04.12.2017.)

- [35] Facebook Help Center. *Pages*.
<https://www.facebook.com/help/282489752085908> (04.12.2017.)
- [36] Facebook Help Center. *Groups*.
<https://www.facebook.com/help/1629740080681586> (04.12.2017.)
- [37] Facebook for Developers. *The Graph API*.
<https://developers.facebook.com/docs/graph-api> (04.12.2017.)
- [38] Facebook Help Center. *Liking & Reacting*.
<https://www.facebook.com/help/452446998120360/> (09.02.2018.)
- [39] Facebook Help Center. *Like and Interact with Pages*.
<https://www.facebook.com/help/1771297453117418/> (09.02.2018.)
- [40] Kissmetrics. *Do You Really Need More Facebook Likes? The Data Driven Answer*.
<https://blog.kissmetrics.com/facebook-likes-data-driven-answer> (06.12.2017.)
- [41] Hubspot. *The Decline of Organic Facebook Reach & How to Outsmart the Algorithm*.
<https://blog.hubspot.com/marketing/facebook-declining-organic-reach>
 (06.12.2017.)
- [42] Wikipedia. *Right-wing politics*.
https://en.wikipedia.org/wiki/Right-wing_politics (22.02.2018.)
- [43] Wikipedia. *Left-wing politics*.
https://en.wikipedia.org/wiki/Left-wing_politics (22.02.2018.)
- [44] Facebook For Developers. *Page - Graphi API Reference*.
<https://developers.facebook.com/docs/graph-api/reference/page/> (23.02.2018.)
- [45] Platforma 112. *Tko smo*.
<http://www.kucaljudskihprava.hr/platforma-112/tko-smo/> (27.12.2017.)
- [46] Facebook Fan Page. *Mreža emancipacije E-net*.
<https://www.facebook.com/emancipacija/about/> (28.12.2017.)
- [47] ŠAGO, V. *Medijska strategija Europske unije prema medijima Trećeg sektora (diplomski rad)*. Zagreb: Fakultet političkih znanosti, 2017.
- [48] Social Media Research Foundation. *NodeXL - Your Social Network Analysis Tool for Social Media*.
<https://www.smrfoundation.org/nodexl/> (07.02.2018.)
- [49] Smith, M. *Osobna korespondencija putem e-mail adrese marc@smrfoundation.org*. (26.09.2017.)

- [50] Gephi. *GraphML Format*.
<https://gephi.org/users/supported-graph-formats/graphml-format/> (19.12.2017.)
- [51] W3Schools. *XML Tutorial*. <https://www.w3schools.com/xml/> (15.12.2017.)
- [52] Gephi. *Pajek NET Format*.
<https://gephi.org/users/supported-graph-formats/pajek-net-format/> (19.12.2017.)
- [53] Gephi. *GEXF File Format*. <https://gephi.org/gexf/format/> (06.01.2018.)
- [54] Gephi. *Gephi Tutorial Quick Start*.
<https://gephi.org/users/quick-start/> (07.01.2018.)
- [55] Gephi. *Gephi Tutorial Layouts*.
<https://gephi.org/users/tutorial-layouts/> (07.01.2018.)
- [56] Github. *Closeness Centrality*.
<https://github.com/gephi/gephi/wiki/Closeness-Centrality> (13.02.2018.)
- [57] BRANDES, U. *A Faster Algorithm for Betweenness Centrality*. Konstanz : KOPS - Institutional Repository of the University of Konstanz, 2001.
- [58] Council Of Europe. *Istanbul Convention*.
<https://www.coe.int/en/web/istanbul-convention/home> (16.02.2018.)
- [59] Wikipedia. *Rodna ideologija*.
https://hr.wikipedia.org/wiki/Rodna_ideologija (16.02.2018.)
- [60] Istina o Istanbulskoj. *Građanska inicijativa Istina o Istanbulskoj*.
<http://www.istinaoistanbulskoj.info/gradanska-inicijativa> (16.02.2018.)
- [61] ADAMIC, L. *Introductory social network analysis with Pajek*. Ann Arbor, MI: University of Michigan, 2008., str. 19.
- [62] QI, X., FULLER, E., WU, Q., WU, Y., ZHANG, C-Q. *Laplacian centrality: A new centrality measure for weighted networks*. New York: Elsevier, Information Sciences, Vol. 194, 240-253, 2012.
- [63] NetworkX. *NetworkX - Software for complex networks*.
<https://networkx.github.io/> (02.01.2018.)
- [64] Apache Software Foundation. *GraphX*.
<https://spark.apache.org/graphx/> (02.01.2018.)

Pod punom odgovornošću pismeno potvrđujem da je ovo moj autorski rad čiji niti jedan dio nije nastao kopiranjem ili plagiranjem tuđeg sadržaja. Prilikom izrade rada koristio sam tuđe materijale navedene u popisu literature ali nisam kopirao niti jedan njihov dio, osim citata za koje sam naveo autora i izvor te ih jasno označio znakovima navodnika. U slučaju da se u bilo kojem trenutku dokaže suprotno, spreman sam snositi sve posljedice uključivo i poništenje javne isprave stečene dijelom i na temelju ovoga rada.

U Zagrebu, XX.02.2018.
